

UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍA ELÉCTRICA
PROGRAMA DE MAESTRIA EN INGENIERÍA
ELÉCTRICA

PREDICCIÓN DEL PRECIO SPOT DE ENERGÍA
ELÉCTRICA EN LA BOLSA DE ENERGIA DE
COLOMBIA

Presentado por:

ANDRES DAVID PINTO RÍOS

Director

ALFONSO ALZATE GÓMEZ

Tesis Presentada Como Requisito Para Optar al Título de Maestría en Ingeniería Eléctrica

Pereira, Julio 2020

PREDICCIÓN DEL PRECIO SPOT DE ENERGÍA ELÉCTRICA EN LA BOLSA DE ENERGIA DE COLOMBIA

UNIVERSIDAD TECNOLÓGICA DE PEREIRA

PEREIRA- RISARALDA

JULIO 2020

PROGRAMA DE MAESTRÍA EN

INGENIERÍA ELÉCTRICA

Andrés David Pinto Ríos
Ingeniero Electricista
2020

AGRADECIMIENTOS

Con alegría y sinceridad expreso mis agradecimientos:

- ✚ A Dios, que con su infinita ubicuidad ha estado presente, iluminando y guiando los pasos de todas las personas que me ayudaron en este camino.
- ✚ A los profesores del programa de Maestría en Ingeniería Eléctrica y a quienes componen su plantel administrativo, por su apoyo y gestión.
- ✚ A la Universidad Tecnológica de Pereira que hizo posible el curso de mis estudios.
- ✚ A mis padres Wilson Pinto y Rosalba Ríos, por su incondicional apoyo y dedicación.
- ✚ A mi tío Luis Hernando Ríos por su desinteresada comprensión, apoyo y orientación.
- ✚ Al profesor Alfonso Alzate por su guía, colaboración y gestión.
- ✚ A mi compañera Karol Narvaez por su dedicación y tenacidad.
- ✚ Al profesor Mauricio Alvarez por su orientación y apoyo.
- ✚ A mi familia, Wilson Daniel Pinto, Miguel Angel Pinto, Liliana Ríos, Blanca Rios, quienes con su sabiduría y acompañamiento han permitido la realización de este y más logros.

Agradezco a todas las personas que de una u otra manera han sido participes en mi formación personal y profesional, que Dios continúe iluminando sus vidas.

Contenido

CAPITULO 1	12
1. INTRODUCCIÓN	12
1.1.1 Objetivo General	12
1.1.2 Objetivos Específicos	12
1.1.3 Definición del problema	13
1.1.4 Justificación del Proyecto	15
1.1.5 Estado del Arte	17
1.1.6 Aportes del Trabajo de Grado	19
CAPITULO 2	20
2. MODELAMIENTO Y TÉCNICAS DE SOLUCIÓN PARA EL PROBLEMA DE PREDICCIÓN DEL PRECIO SPOT DE ENERGÍA ELÉCTRICA	20
2.1. TERMINOLOGIA Y MODELAMIENTO CONCEPTUAL DEL PROBLEMA	20
2.1.1. Mercado Eléctrico Colombiano	20
2.2. ORGANIZACIÓN DEL SECTOR	22
2.2.1. Componentes y Agentes del Mercado	24
2.2.2. Tipos de Contratos	27
2.2.3. Mercado de Energía Mayorista	29
2.2.4. Bolsa de energía en Colombia	30
2.2.5. Cálculo del Precio en Bolsa de Energía	32
2.3. METODOS Y TECNICAS USADAS EN LA SOLUCION DEL PROBLEMA	33
2.3.1. Métodos Basados en Tratamientos Bayesianos	33
2.3.2. Procesos Gaussianos para Regresión y Máquinas de soporte de relevancia	35
2.3.3. Series Temporales Basados en técnicas Econométricas de Medias Móviles	37
2.3.4. Modelos AR (Modelo estocástico Autor regresivo) de Primer Orden	39

2.3.5.	Modelo Autor regresivo Integrado de Media Móvil (ARIMA)	42
2.3.6.	Métodos de Optimización exacta	43
2.3.7.	Mínimos Cuadrados	45
2.3.8.	Método de Validación Cruzada Holdout.....	46
2.3.9.	Mínimos Cuadrados Regularizados Con Representación No Lineal.	47
2.3.10.	Método de regresión usando modelo de kernel rígido	48
2.3.11.	Kernel de Filtro Adaptativo.....	50
2.4.	BIBLIOGRAFÍA.....	53
CAPITULO 3		57
3.	RESULTADOS	57
3.1.	Introducción	57
3.2.	Modelación ARIMA	58
3.3.	Modelación de Regresión Gaussiana	95
CAPITULO 4		132
4.	CONCLUSIONES	132

Índice de Figuras

FIGURA 1. Evolución de las pérdidas de energía en Colombia 1970-1997 (fuente: ISA)	23
FIGURA 2. Esquema Organizacional Sector Eléctrico Colombiano.....	24
FIGURA 3. Estructura del Mercado Energético Colombiano.....	27
FIGURA 4. Curva de Oferta (Demanda Vs Precio de Oferta).....	32
FIGURA 5. Validación Cruzada Hold Out	47
FIGURA 6. Kernel de Filtro Adaptativo Para la Identificación no Lineal del Sistema	51
FIGURA 7. Visualización dato de predicción para el día 147	59
FIGURA 8. Visualización dato de predicción para el día 147	59
FIGURA 9. Función de Autocorrelación vs Retardo	60
FIGURA 10. Función de Autocorrelación vs Retardo.	61
FIGURA 11. Función De Auto Correlación vs Retardo Dato 300.....	64
FIGURA 12. FACP vs Retardo Dato 300.....	65
FIGURA 13. Visualización dato de predicción 300.....	66
FIGURA 14. Visualización dato de predicción 300 (Rango Acotado).....	66
FIGURA 15. Función de Autocorrelación vs Retardo día 360	68
FIGURA 16. FACP vs Retardo día 360.....	69
FIGURA 17. Visualización dato de Predicción 360.	69
FIGURA 18. Visualización dato de Predicción 360 (Rango Acotado).....	70
FIGURA 19. Función de Auto Correlación Día 388.....	70
FIGURA 20. FACP vs Retardo Día 388.....	71
FIGURA 21. Visualización Dato de Predicción Día 388.....	71
FIGURA 22. Visualización Dato De Predicción Día 388.....	72
FIGURA 23. Función de Auto Correlación vs Retardo Día 410	73
FIGURA 24. FACP vs Retardo Día 410.....	73
FIGURA 25. Visualización Dato de Predicción Día 410.....	74
FIGURA 26. Visualización Dato de Predicción Día 410 (Rango Acotado)	74
FIGURA 27. Función de Auto Correlación vs Retardo Día 490.	75
FIGURA 28. FACP vs Retardo Día 490.....	76

FIGURA 29. Visualización Dato de Predicción Día 490.....	76
FIGURA 30. Visualización Dato de Predicción Día 490 (Rango Acotado)	77
FIGURA 31. Función de Auto Correlación vs Retardo Día 520	77
FIGURA 32. FACP vs Retardo Día 520.....	78
FIGURA 33. Visualización Dato de Predicción Día 520.....	78
FIGURA 34. Visualización Dato de Predicción Día 520.....	79
FIGURA 35. Visualización Dato de Predicción Día 580.....	79
FIGURA 36. Visualización Dato de Predicción Día 580 (Rango Acotado)	80
FIGURA 37. Función de Auto Correlación vs Retardo Día 580	80
FIGURA 38. Visualización Dato De Predicción Día 630.....	81
FIGURA 39. Visualización Dato de Predicción Día 630 (Rango Acotado)	81
FIGURA 40. Función de Auto Correlación vs Retardo Día 630	82
FIGURA 41. FACP vs Retardo Día 630.....	82
FIGURA 42. Visualización Dato de Predicción Día 650.....	83
FIGURA 43. Visualización Dato de Predicción Día 650 (Rango Acotado)	83
FIGURA 44. Función de Auto Correlación vs Retardo Día 650	84
FIGURA 45. FACP vs Retardo Día 650.....	84
FIGURA 46. Visualización Dato de Predicción Día 710.....	85
FIGURA 47. Visualización Dato de Predicción Día 710 (Rango Acotado)	85
FIGURA 48. Función de Auto Correlación vs Retardo Día 710	86
FIGURA 49. FACP vs Retardo Día 710.....	86
FIGURA 50. Visualización Dato de Predicción Día 840.....	87
FIGURA 51. Visualización Dato de Predicción Día 840 (Rango Acotado)	87
FIGURA 52. Función de Auto Correlación vs Retardo Día 840	88
FIGURA 53. FACP vs Retardo Día 840.....	88
FIGURA 54. Visualización Dato de Predicción Día 955.....	89
FIGURA 55. Visualización Dato de Predicción Día 955 (Rango Acotado)	89
FIGURA 56. Función de Auto Correlación vs Retardo Día 955	90
FIGURA 57. FACP vs Retardo Día 955.....	90
FIGURA 58. Visualización Dato de Predicción Día 1033.....	91
FIGURA 59. Visualización Dato de Predicción Día 1033 (Rango Acotado)	92
FIGURA 60. Función de Auto Correlación vs Retardo Día 1033	92
FIGURA 61. FACP vs Retardo Día 1033.....	93

FIGURA 62. Estimación día 300 Mínimos Cuadrados No Lineales	96
FIGURA 63. Estimación Punto Dato 300 Mínimos Cuadrados No Lineales	96
FIGURA 64. Estimación Punto Día 300 Usando distribución de Kernel Rígido	97
FIGURA 65. Estimación Punto Dato 300 Usando Distribución De Kernel Rígido.....	98
FIGURA 66. Estimación Dato 300 Distribución de Kernel de Filtro Adaptativo	99
FIGURA 67. Estimación Dato 300 Distribución De Kernel De Filtro Adaptativo.....	99
FIGURA 68. Comparación de Curvas Por Diferentes Métodos De Kernel.....	100
FIGURA 69. Comparación de Curvas Por Diferentes Métodos De Kernel.....	101
FIGURA 70. Estimación Punto Dato 360 Mínimos Cuadrados No Lineales	101
FIGURA 71. Estimación Punto Dato 360 Mínimos Cuadrados No Lineales	102
FIGURA 72. Estimación Punto Día 360 Regresión con Kernel Rígido	103
FIGURA 73. Estimación Punto Día 360 Regresión con Kernel Rígido	104
FIGURA 74. Estimación Punto Día 360 Regresión con Kernel del Filtro Adaptativo.....	105
FIGURA 75. Estimación Punto Día 360 Regresión con Kernel del Filtro Adaptativo.....	105
FIGURA 76. Comparación de Curvas Por Diferentes Métodos de Kernel.....	106
FIGURA 77. Estimación Punto Día 410 Mínimos Cuadrados No Lineales	107
FIGURA 78. Estimación Punto Día 410 Mínimos Cuadrados No Lineales	107
FIGURA 79. Estimación Punto Día 410 Regresión con Kernel Rígido	108
FIGURA 80. Estimación Punto Día 410 Regresión con Kernel Rígido	109
FIGURA 81. Estimación Punto Día 410 Regresión con Kernel del Filtro Adaptativo.....	110
FIGURA 82. Estimación Punto Día 410 Regresión con Kernel del Filtro Adaptativo.....	111
FIGURA 83. Comparación De Curvas Por Diferentes Métodos De Kernel.....	112
FIGURA 84. Comparación De Curvas Por Diferentes Métodos De Kernel.....	112
FIGURA 85. Estimación Punto Dato 540 Mínimos Cuadrados No Lineales	113
FIGURA 86. Estimación Dato 540 Mínimos Cuadrados No Lineales	113
FIGURA 87. Estimación Día 540 Regresión con Kernel Rígido.....	114
FIGURA 88. Estimación Día 540 Regresión con Kernel Rígido.....	115
FIGURA 89. Estimación Día 540 Regresión con Kernel del Filtro Adaptativo	116
FIGURA 90. Estimación Punto Dato 540 Regresión con Kernel del Filtro Adaptativo.....	116
FIGURA 91. Comparación De Curvas Por Diferentes Métodos De Kernel.....	117
FIGURA 92. Comparación de Curvas Por Diferentes Métodos De Kernel.....	118
FIGURA 93. Estimación Día 630 Mínimos Cuadrados No Lineales	118
FIGURA 94. Estimación Dia 630 Mínimos Cuadrados No Lineales	119

FIGURA 95. Estimación Día 300 Regresión con Kernel Rígido.....	120
FIGURA 96. Estimación Punto Dato 300 Regresión con Kernel Rígido	120
FIGURA 97. Estimación Punto Dato 630 Regresión con Kernel del Filtro Adaptativo.....	121
FIGURA 98. Estimación Punto Dato 630 Regresión con Kernel del Filtro Adaptativo.....	122
FIGURA 99. Comparación De Curvas Por Diferentes Métodos De Kernel	123
FIGURA 100. Comparación De Curvas Por Diferentes Métodos De Kernel	123
FIGURA 101. Estimación Punto Dato 670 Mínimos Cuadrados No Lineales	124
FIGURA 102. Estimación Punto Dato 670 Mínimos Cuadrados No Lineales	125
FIGURA 103. Estimación Punto Dato 670 Regresión con Kernel Rígido	126
FIGURA 104. Estimación Punto Dato 670 Regresión con Kernel Rígido	126
FIGURA 105. Estimación Punto Dato 670 Regresión con Kernel del Filtro Adaptativo.....	127
FIGURA 106. Estimación Punto Dato 670 Regresión con Kernel del Filtro Adaptativo.....	128
FIGURA 107. Comparación de Curvas Por Diferentes Métodos De Kernel.....	129
FIGURA 108. Comparación de Curvas Por Diferentes Métodos De Kernel.....	129

Índice de Tablas

TABLA 1. Resultados ARIMA (Ejemplo Base).....	62
TABLA 2. Comparativo error porcentual	63
TABLA 3. Predicción e Hiperparámetros Día 360	68
TABLA 4. Predicción e Hiperparámetros Día 388	70
TABLA 5. Predicción e Hiperparámetros Día 410	72
TABLA 6. Predicción e Hiperparámetros Día 490	75
TABLA 7. Predicción e Hiperparámetros Día 520	77
TABLA 8. Predicción e Hiperparámetros Día 580	79
TABLA 9. Predicción e Hiperparámetros Día 630	81
TABLA 10. Predicción e Hiperparámetros Día 650	83
TABLA 11. Predicción e Hiperparámetros Día 710	85
TABLA 12. Predicción e Hiperparámetros Día 840	87
TABLA 13. Predicción e Hiperparámetros Día 955	89
TABLA 14. Predicción e Hiperparámetros Día 1033	91
TABLA 15. Resultados Modelo De Predicción ARIMA.....	94
TABLA 16. Predicción e Hiperparámetros Día 300 Mínimos Cuadrados No Lineales	97
TABLA 17. Predicción e Hiperparámetros Día 300 Distribución de Kernel Rígido.....	98
TABLA 18. Predicción e Hiperparámetros Día 300 Regresión con Kernel De Filtro Adaptativo .	100
TABLA 19. Predicción e Hiperparámetros Día 360 Mínimos Cuadrados No Lineales	102
TABLA 20. Predicción e Hiperparámetros Día 300 Regresión con Kernel Rígido.....	104
TABLA 21. Predicción e Hiperparámetros Día 360 Regresión con Kernel del Filtro Adaptativo .	106
TABLA 22. Predicción e Hiperparámetros Día 410 Mínimos Cuadrados No Lineales	108
TABLA 23. Predicción E Hiperparámetros Día 410 Regresión con Kernel Rígido.....	109
TABLA 24. Predicción e Hiperparámetros Día 410 Regresión con Kernel del Filtro Adaptativo .	111
TABLA 25. Predicción e Hiperparámetros Día 540 Mínimos Cuadrados No Lineales	114
TABLA 26. Predicción e Hiperparámetros Día 540 Regresión con Kernel Rígido.....	115
TABLA 27. Predicción e Hiperparámetros Día 540 Regresión con Kernel del Filtro Adaptativo .	117
TABLA 28. Predicción E Hiperparámetros Día 630 Mínimos Cuadrados No Lineales.....	119
TABLA 29. Predicción E Hiperparámetros Día 630 Regresión con Kernel Rígido.....	121
TABLA 30. Predicción e Hiperparámetros Día 540 Regresión con Kernel del Filtro Adaptativo .	122

TABLA 31. Predicción E Hiperparámetros Día 630 Mínimos Cuadrados No Lineales.....	125
TABLA 32. Predicción e Hiperparámetros Día 670 Regresión con Kernel Rígido.....	127
TABLA 33. Predicción e Hiperparámetros Día 670 Regresión con Kernel del Filtro Adaptativo. .	128
TABLA 34. Resultados Modelo KLMS Regularizado	130
TABLA 35. Resultados Modelo de Kernel Rígido	130
TABLA 36. Resultados Kernel de filtro Adaptativo.....	131

CAPITULO 1

El capítulo 1 consta de los parámetros justificativos, definición del problema y presentación de soluciones para el problema.

1. INTRODUCCIÓN

1.1.1 Objetivo General

Establecer un método efectivo para la estimación del precio Spot de energía eléctrica en la bolsa de energía colombiana.

1.1.2 Objetivos Específicos

- Realizar la estimación del precio Spot usando un Análisis de series temporales cuyo método es un modelo autorregresivo integrado de medias móviles (ARIMA).
- Realizar la estimación del precio Spot usando un método basado en un modelo gaussiano de aprendizaje supervisado
- Realizar el mapeo del espacio de entradas y predicción usando tres alternativas de funciones Kernel (Kernel de mínimos cuadrados regularizados, Kernel rígido, Kernel de filtro adaptativo)
- Realizar una comparación entre los métodos utilizados y verificar cual es el más eficiente para la predicción del precio spot.

1.1.3 Definición del problema

En Colombia y el mundo se hacen grandes esfuerzos orientados a mejorar la calidad, intensidad, capacidad y continuidad del suministro eléctrico, con el fin de mejorar éste recurso, que hoy por hoy es uno de los más importantes a nivel socio económico para el desarrollo y avance de una sociedad y que involucra diferentes estamentos y entidades las cuales se encargan de mantener una serie de características fundamentales para su suministro, éstas características son dadas por la propia estructura del sistema, definida principalmente en tres grandes sectores, generación, transmisión y distribución. En el caso específico de la demanda de energía y la fijación de su precio en el mercado eléctrico Colombiano (Mercado Eléctrico Mayorista) se habla de la especificación de este precio como un valor para soportar las transacciones entre generadores y comercializadores y ajustar las dádivas dependiendo los tipos de contratos, los generadores lo usan para planificar su producción, decidir sobre sus inversiones, definir sus contratos y cubrir sus riesgos, además de pactar el precio en bolsa de la energía teniendo en cuenta los estatutos a cumplir ante los agentes reguladores.

En la transmisión, estos valores son usados para el diseño físico y topológico de la red. Todas estas características son para los entes comercializadores un insumo esencial para la compra y venta de energía, además que para la operación del sistema una mayor precisión en la demanda equivale a una mayor precisión del despacho real de los diferentes recursos de generación y por ende una mejor aproximación al precio

ideal con el que se pactan los convenios y contratos para la compra y venta de energía, lo cual a largo plazo es un índice de inversión en nueva capacidad instalada.

Teniendo claro todos los factores que intervienen en la producción de la energía eléctrica, es de resaltar entonces la gran importancia de tener precisión en la predicción de sus variables, que de no ser así puede traer altos costos económicos

para todos los entes involucrados como lo son generadores, transmisores, comercializadores entre otros.

Existen varias razones por las que se puede explicar la dificultad al realizar predicciones acertadas del precio de la energía, por ejemplo, la complejidad de sus factores determinantes como el clima, temporadas de lluvias o sequías, el horizonte de pronóstico, la topología del sistema y sus limitaciones físicas, las restricciones propias de las metodologías utilizadas, la dependencia directa en cuanto a la variabilidad de otros mercados (gas, petróleo, carbón, emisiones, etc.). Éstos inconvenientes a la hora de hacer predicción de las variables, pueden ser superados en gran parte gracias a la forma de afrontar dichas restricciones puntualizando algunos parámetros que ayuden a delimitar cada problema, por ejemplo, especificando el tipo de predicción a la que se va a someter el sistema, la cantidad de datos utilizados, la naturaleza de los datos, la tasa de representación de la predicción en el sistema global, entre otros.

1.1.4 Justificación del Proyecto

En las últimas décadas el sector eléctrico colombiano ha sufrido una serie de modificaciones tanto en su estructura física como en su organización, en donde a través del avance tecnológico mundial y las necesidades de la sociedad, la energía eléctrica se ha convertido en un insumo fundamental tanto para los agentes gestores del sistema eléctrico, como para los consumidores; es primordial y de gran relevancia para la economía y el desarrollo de la sociedad la eficiencia en la prestación del servicio; dicha eficiencia depende de múltiples variables y factores que están ligados directa o indirectamente uno del otro y que al involucrarlos en un sistema dinámico deben seguir una serie de parámetros que indiquen su eficacia al obtener su resultado final, uno de estos parámetros e indicadores importantes, es la fijación del precio de la energía eléctrica en la bolsa de todo sistema interconectado, ya que todos los agentes participantes en la generación, transmisión, distribución e intermedios deben tener un índice de confiabilidad o eficiencia en sus acciones, y gracias a la predicción del precio de la energía muchos de estos agentes obtienen tal indicador.

A pesar de la cantidad de variables y valores incidentes en la producción de energía eléctrica, se han desarrollado técnicas de diferente índole, matemáticas, estadísticas, probabilísticas, econométricas entre otras que han facilitado su predicción y así han elevado en gran proporción la fiabilidad en los sistemas eléctricos.

En este documento se emplearan dos tipos de técnicas de predicción, las cuales se fundamentan en regresiones no lineales, una de ellas esta basadas en un modelo gaussiano de aprendizaje supervisado (Regresión Gaussiana) y la otra técnica es un método econométrico para la aproximación auto regresiva de patrones (ARIMA) el cual es el más utilizado para éste tipo de datos, el objetivo es utilizar las dos metodologías propuestas para predecir el precio en bolsa de la energía eléctrica utilizando una base de datos real (existente) , y comparar los resultados obtenidos de un método con el otro, se procederá a dar un juicio sobre cuál presenta mejores resultados y su incidencia en la toma de decisiones frente a la compra y venta de

energía en la bolsa de energética colombiana, teniendo en cuenta varios factores, como la naturaleza estocástica de los datos, su estacionalidad, los datos no comunes, su modelo como función de probabilidad si es el caso, y las características del conjunto de datos, etc.

Ya que la energía eléctrica tiene diversos factores que afectan su generación, transmisión y distribución, es válido mencionar que los métodos planteados en éste documento están basados en variables no intrínsecas al proceso de producción de electricidad (las variables fundamentales están ligadas a los datos obtenidos) , por lo que se basa en datos del pasado, lo que constituye una adhesión de los fenómenos de índole primaria, como lo son cambios atmosféricos, cambios y fenómenos climáticos, alza de otras divisas, inclusión del comportamiento de otros mercados (carbón, gas, emisiones...etc.) lo que proporciona una ventaja ya que al enfocar el estudio en los datos, éstas variables están ligadas al valor de cada dato.

Los métodos de regresión son modelos que permiten desarrollar una serie de lineamientos y parámetros para la predicción de valores de una variable numérica con base en los valores de una o más variables diferentes, la variable dependiente es la que se desea predecir, y aquellas que se utilizan para dicha predicción son llamadas variables independientes, no obstante se puede encontrar aparte de los valores de la variable o variables dependientes, una función matemática que describa la relación entre las variables dependientes e independientes para una cuantificación de la incidencia que los cambios de las variables independientes tienen sobre las dependientes además de aportar información sobre observaciones inusuales.

Debido a lo anterior, se han buscado técnicas para la solución de este problema; no obstante, ya que se modela como uno de predicción de datos de naturaleza estocástica es de resaltar que los métodos son interdisciplinarios, lo que conlleva a tener muchas posibilidades a la hora de afrontarlos y de dar aplicación a las herramientas que se presentan.

1.1.5 Estado del Arte

Uno de los métodos más usados por economistas, estadistas y matemáticos, son los modelos regresivos que modifican la media de los datos ya sea con desplazamientos (medias móviles) o con el incremento de las variables de innovación (bias), en [1] se observa un modelamiento SARIMAX para la predicción del precio spot de energía eléctrica (Seasonal ARIMA with Exogenous Variables) en donde la base del tratamiento de los datos estocásticos es dada por un modelo auto regresivo integrado de medias móviles con un polinomio auto regresivo de orden p y otro de medias móviles de orden Q los cuales tienen una tendencia estacional; éste término estacional se entiende como una pauta del comportamiento cíclico en el conjunto de características en un periodo de tiempo, lo cual implica una regularidad en el comportamiento particular de una serie, por lo que se pueden ver cambios de niveles bruscos, sin embargo a través del tiempo algunos patrones se repiten, además de esto se adiciona un parámetro externo al modelo (exógeno) de orden $t-h$ el cual suma un grado dimensional más al conjunto de innovaciones intrínsecas al método base con la finalidad de que los datos que se adicionan suman dimensionalmente un estado más a la media y la varianza del modelo lo que conlleva a una mayor robustez y mejores resultados a la hora de analizar los datos; así en [2], [3] se tienen como punto de comparación dos métodos diferentes para la predicción del precio spot de energía eléctrica, ya que uno es un método econométrico basado en un modelo ARIMA y por otro lado un método inteligente ANN (red neuronal artificial), en [42] los autores implementan un modelo ARIMA para la predicción de la demanda de electricidad en el mercado eléctrico Colombiano.

De igual manera, otro método para la solución de éste tipo de problemas son las máquinas de vectores de relevancia (RVM) son un tratamiento bayesiano de una función de decisión similar a la de una SVM, pero que no sufre de algunas de sus desventajas, y teniendo en cuenta que se basa en un método de aprendizaje supervisado en donde la estrategia que se utiliza convencionalmente es tomar

aleatoriamente un subconjunto de la totalidad de pares observación-etiqueta para entrenar algún clasificador y los restantes para efectuar un proceso de validación.

En [4] es usado el método de Vectores de soporte de Relevancia para la predicción del precio spot de la energía eléctrica, en este caso se usan dos funciones Kernel, lo que lo convierte entonces en un método de multi regresión, ya que las dos máquinas de soporte de relevancia se usan para el mismo fin, sin embargo las funciones kernel dan una serie de características a cada resultado, las cuales son evaluadas, categorizadas y convertidas en un método de optimización el cual es resuelto con una técnica llamada (mGA) Micro Algoritmo Genético.

De igual forma en [32] se observa la predicción del precio spot de energía eléctrica combinando un modelo KF (Filtro de Kalman) y un modelo GARCH (Generalized Autorregressive Conditional Heteroschedasticity) en éste, con el modelo GARCH realiza el cálculo y predicción del estado siguiente teniendo en cuenta los datos del pasado, y el modelo KF se usa para ajustar y actualizar los parámetros dentro del modelo de predicción.

En [33] se usa la versión del algoritmo LMS para la predicción de la potencia del viento usando el truco de kernel para la actualización de las muestras para la reproducción del espacio de Hilbert (KLMS), además se realiza una variación en donde las dependencias de las variables cambian con el tiempo y se actualizan en la función inicial haciendo éste un método en línea.

En [34] los autores usan algoritmos y métodos de mínimos cuadrados regularizados, para la caracterización de las señales remotas de electro cardiogramas y eliminar el llamado “Baseline Wandering”, el cual según se explica en el documento es el fenómeno que describe una de las perturbaciones principales que afectan la forma de representación de la señal.

1.1.6 Aportes del Trabajo de Grado

Los aportes más relevantes de este trabajo de grado son los siguientes:

- La especificación y validación de un método efectivo para la predicción del precio SPOT de energía eléctrica (Kernel LMS regularizado) el cual consiste en una técnica basada en un modelo gaussiano de aprendizaje supervisado.
- La validación de uno de los modelos más utilizados para el desarrollo de metodologías de predicción, el cual consiste en la modelación de series temporales por medio de una serie autorregresiva de medias móviles (ARIMA).
- La confirmación de que el uso de métodos clásicos presenta aproximaciones bastante aceptables en comparación a los métodos y modelamientos actuales.

CAPITULO 2

El capítulo 2 consta de los modelos y técnicas utilizadas para la solución del problema.

2. MODELAMIENTO Y TÉCNICAS DE SOLUCIÓN PARA EL PROBLEMA DE PREDICCIÓN DEL PRECIO SPOT DE ENERGÍA ELÉCTRICA

2.1. TERMINOLOGIA Y MODELAMIENTO CONCEPTUAL DEL PROBLEMA

2.1.1. Mercado Eléctrico Colombiano

[5] El mercado eléctrico colombiano, a través del tiempo ha sufrido grandes y significativas modificaciones, desde un cambio en el monopolio público al modelo de mercado como lo conocemos ahora; este mercado está basado en el modelo del mercado eléctrico de Gales, sin embargo, existen diferencias sustanciales propias de las características de cada sistema.

Actualmente el mercado de energía eléctrica se establece a partir de las leyes 142 y 143 de 1994 y es de tipo mayorista, donde se pretende la prestación del servicio de manera eficiente, posibilitando la libre entrada a los agentes interesados en prestarlo. Estos agentes, están constituidos por una estructura jerárquica y desarrollan actividades de generación, transmisión, distribución y comercialización, y están coordinados por el CND de acuerdo a la resolución 080 de 1999 CREG.

El mercado de energía mayorista cuenta con dos mecanismos principales para la negociación de energía eléctrica: los contratos bilaterales y las transacciones en bolsa de energía.

Los contratos bilaterales son mecanismos a largo plazo que permiten negociar el suministro de electricidad entre agentes del mercado (generadores o comercializadores) por un periodo de tiempo definido a un precio determinado.

Por su parte, la bolsa de energía es una instancia en la cual se negocia la energía eléctrica con unas condiciones de precio de la energía variable, el cual se determina de acuerdo con la disponibilidad de recursos de generación, al precio solicitado por los agentes y a las predicciones de demanda que fija el operador del sistema.

Además, el mercado mayorista maneja mecanismos para la retribución económica a los agentes por la disponibilidad de los recursos de generación a través de los cargos por confiabilidad, y mecanismos de reconciliación por diferencias entre energía programada y despachada; se retribuye económicamente a los agentes generadores que prestan el servicio de regulación secundaria de frecuencia, y recauda los cargos por conexión y uso de las redes de transmisión y distribución que se cancelan a las respectivas empresas prestadoras de este servicio.

[6] La principal característica es que se realiza un despacho (orden centralizado) por precepto de mérito el cual busca suplir las curvas de demanda y de ofertas de precios de los participantes del mercado

Para fijar dicho precio, los generadores ofrecen un esquema de su actividad de oferta, en donde se especifican la cantidad de unidades disponibles, la capacidad instalada y dispuesta a ser utilizada, el precio al cual está pactada su oferta para proporcionar energía al día siguiente. El ente encargado del despacho (CND-Centro Nacional de Despacho) se encarga de calcular la generación de cada una de las plantas de forma tal que se cubra la curva de demanda en donde la generación de las centrales que minimizan costos de operación son las que cierran cada hora el precio de la energía, además de calcular el precio de la planta marginal (la última que oferta).

2.2. ORGANIZACIÓN DEL SECTOR

[7] Durante gran parte de la década de los 70 y 80 como principal estructura en el sector eléctrico se tenía un modelo de generación centralizada con empresas estatales integradas de manera vertical, enfocada en las zonas de gran población (Cundinamarca, Antioquia, parte del Valle y Caldas) y con el propósito de desarrollar el potencial hidroeléctrico y generar el servicio con la mayor cobertura sin priorizar otros factores; la historia del sector eléctrico colombiano se caracterizó entonces por la búsqueda continua de un mejor desempeño para acceder a los créditos internacionales para inversiones en generación que imponía un crecimiento acelerado de la demanda y la ampliación de la cobertura del mercado, en pocas palabras; en aquella época, tanto las tarifas como los niveles de pérdidas no eran motivo de preocupación, y el desafío consistía en lograr una expansión de la generación en forma eficiente mediante la interconexión de los sistemas que permitiera utilizar economías de escala y desarrollar el potencial hidroeléctrico, siguiendo un camino de costo mínimo. Tal paradigma estatal fue llamado el paradigma de “la mano auxiliadora” o “helping hand”. La estructura institucional resultante de esta combinación de circunstancias, entidades y agentes, cada uno con distintos intereses por defender, tanto nacionales como regionales desencadenaban consecuencias como la regulación del estado a medias, el estado empresario a medias, que pregona autosuficiencia financiera y traza políticas tarifarias ruinosas para las empresas eléctricas, un sector en donde las consecuencias no son asumidas por quienes las toman.

Durante los años 80 los privilegios económicos por parte de las entidades extranjeras fueron cancelados por motivo de la crisis de la deuda, además que las pérdidas eléctricas aumentaron significativamente pese a los esfuerzos que se hacían por remediarlo; a las condiciones anteriores, se le sumaban los atrasos y sobrecostos de uno de los proyectos pioneros en el país como lo fue Guavio lo cual se vio reflejado

en el racionamiento de 1992; sin embargo mucho antes (1991) resultaba claro para el gobierno que no podía seguir adelante sin una transformación radical en el sector.




FIGURA 1. Evolución de las pérdidas de energía en Colombia 1970-1997 (fuente: ISA)

Es entonces cuando a partir del año 1991 se plantean estrategias de fondo para una reorganización del sector eléctrico colombiano, en donde se le daba una participación importante a la empresa privada, con el fin de buscar la eficiencia en la operación y en la distribución de recursos, además de evitar que estos fuesen proporcionados exclusivamente por el estado; en este caso la idea es proporcionar mejoras en tarifas, en servicio, en infraestructura, todo bajo un marco jurídico que estandarizaran y vigilaran los procedimientos.

En 1994 se promulgan las leyes 142 (ley de servicios públicos domiciliarios) y 143 (ley eléctrica) en donde se define la separación del sector, en los diferentes agentes (Generación, transmisión, distribución, comercialización) que hoy se constituyen como las partes principales del sistema, además de esto se crean nuevas entidades encargadas de regular, planear, vigilar y controlar la operación del sistema, es los casos de la superintendencia de servicios públicos domiciliarios (vigilancia y control), la comisión de regulación de energía y gas CREG (regulación), la unidad de planeación minero energética UPME, creando así en 1995 el mercado de energía mayorista operado principalmente por la compañía ISA (interconexión eléctrica S.A.) por medio del CND (centro nacional de despacho) y su filiar XM compañía principalmente adecuada para el estudio de mercados.

Para cumplir con los objetivos mínimos de reestructuración del sector, el gobierno buscó crear organismos de regulación control y planeación, con el fin de crear Figuras económicas competitivas y transparentes, y que los procesos asociados a cada uno de los agentes que integren el sistema estén debidamente basados y desarrollados en leyes y estatutos legales.

Es así como por medio de una integración de sectores, se buscó una consolidación económica del mercado, creando mejoras en el servicio, las tarifas, la estructura, operaciones, de tal forma que se incentivara a las empresas privadas a invertir en el sistema eléctrico colombiano sin dejar atrás el hecho de que tenían Figuras autoritarias por parte del estado.

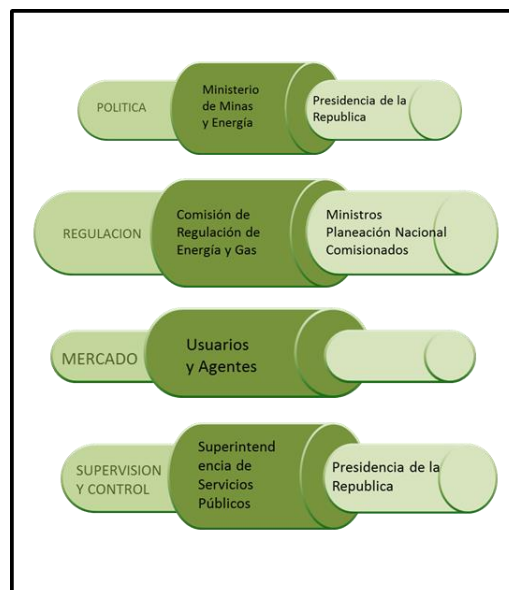


FIGURA 2. Esquema Organizacional Sector Eléctrico Colombiano

2.2.1. Componentes y Agentes del Mercado

- Generación

[6][8] El proceso de generación de energía es uno de los procesos principales en la cadena de actividades que constituyen el sistema eléctrico colombiano, la cual abarca diferentes tecnologías y propiedades que dependen del lugar y la topología de la región; como bien se

conoce en Colombia se tiene gran riqueza hidroeléctrica, lo que ha sido aprovechado en gran parte por la sociedad para la generación y el aprovechamiento de la energía eléctrica.

Los agentes generadores, son aquellas entidades encargadas de generar el fluido eléctrico, el cual puede originarse de diferentes maneras dependiendo el recurso primario para su generación; es el caso de la generación térmica, hidroeléctrica, eólica, fotovoltaica, nuclear, entre otros. Es así como la generación en el sistema eléctrico colombiano se basa en su mayoría en producción hidroeléctrica, con un 65% y el restante para energía térmica y eólica, en donde el precio de la energía se puede transar en la bolsa de energía o mediante contratos bilaterales entre comercializadores u otros generadores o grandes usuarios, quienes ofertan la disponibilidad para sus recursos generadores al CND para este elabore el despacho económico para las 24 horas siguientes.

Existen diferentes tipos de generadores, los cuales ajustan su disponibilidad y capacidad dependiendo de los recursos y la Figura jurídica a la cual está ligada su actividad:

- El auto generador, personas naturales o jurídicas que generan energía eléctrica para sus propias necesidades, y suplir así su propia demanda de energía y su conexión a la red de alimentación pública, es exclusivamente como sistema de respaldo ante posibles fallas.
- Los generadores que posean plantas o unidades de generación conectadas al Sistema Interconectado Nacional con capacidad mayor a 10 MW.
- Cogeneradores, siendo aquellas personas naturales o jurídicas que producen energía eléctrica combinada; además de vender sus excedentes ante el mercado eléctrico mayorista.

- Transmisión

[6][8] Se le llama Transmisión eléctrica a la actividad dedicada al transporte de energía eléctrica a través de un sistema interconectado a tensiones de operación iguales o superiores a 220 kV o a través de redes de conexión regionales que operen a niveles inferiores de tensión. El STN (Sistema de Transmisión Nacional - Colombiano) se constituye por todas aquellas personas naturales o jurídicas que cumplan las condiciones técnicas, económicas y

financieras que efectúen y cumplan los parámetros pactados y licitaciones públicas dictadas por la UPME (Unidad de Planeación Minero Energética). En Colombia se divide en cinco grandes subsistemas: sistema central, oeste, sur, noroeste y nordeste quienes se encargan de transportar la energía eléctrica a la gran mayoría de regiones del país.

- Distribución

[6][8] La actividad de distribución se asocia al transporte de la energía eléctrica a través de sistemas de interconexión con niveles de tensión menores a 220 kV, además sus principales componentes son líneas de distribución regional, municipal, y las subestaciones y componentes necesarios para la distribución local de energía a un territorio determinado los cuales están directamente ligados con el STN.

Los niveles de tensión para la distribución de energía se clasifican en los siguientes:

Nivel 4: sistema con tensión nominal mayor o igual a 57,5 kV y menor a 220 kV.

Nivel 3: Sistemas con tensión nominal mayor o igual a 30 kV y menor de 57,5 kV.

Nivel 2: Sistemas con tensión nominal mayor o igual a 1 kV y menor de 30 kV.

Nivel 1: Sistemas con tensión nominal menor de 1 Kv.

Actualmente todas las empresas de distribución a su vez son comercializadoras, pero no todas las empresas comercializadoras son distribuidoras;

- Comercialización

[6][8] Los agentes comercializadores son aquellos que prestan el servicio de intermediación entre los generadores, transmisores y distribuidores, y se encarga de la compra y venta de energía, siendo así su compra en el mercado eléctrico mayorista y su venta en el mismo mercado o a los usuarios finales (regulados o no regulados), los cuales tienen la propiedad de elegir la empresa comercializadora para su servicio, además de un acceso a generadores competitivos para un mejor servicio según sea el caso, lo que se llamó un modelo de competencia minorista.

Ya que los entes de generación y comercialización están establecidos a parte del proceso de transporte (transmisión y distribución) dichos entes realizan transacciones operativas, y comerciales en el MEM bajo dos modalidades principales:

Suscripción de contratos financieros bilaterales de compra y venta de energía, y cuyos precios están pactados y estandarizados por cada parte (compradores y vendedores).

Por medio de transacciones directas en bolsa de energía en donde los precios se determinan por medio de una subasta de generadores y cuyo contexto de contrato se rigen bajo un sistema de mercado spot de régimen horario.

2.2.2. Tipos de Contratos

[6][8][31] A través del Mercado de Energía Mayorista se realizan las transacciones de compra y venta de energía, en donde se realizan las negociaciones comerciales mencionadas, además de otros servicios relacionados con el suministro. Este mercado se compone por un mercado físico y uno financiero

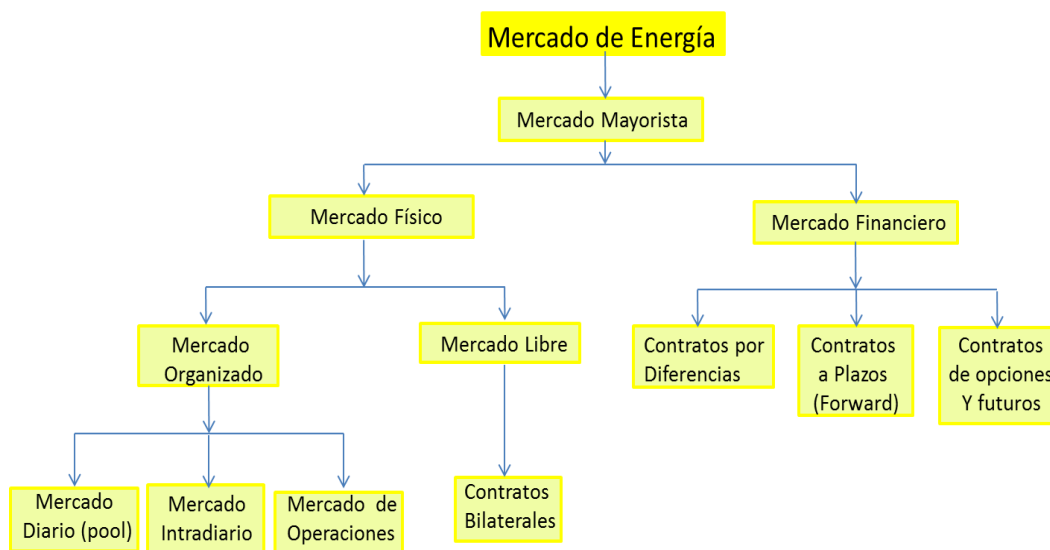


FIGURA 3. Estructura del Mercado Energético Colombiano

Contrato por diferencias: Es aquel contrato libre entre dos partes, por el que el vendedor se obliga a pagar al comprador las diferencias positivas entre un precio de referencia (precio del mercado) y un precio de ejercicio (precio del contrato) a cambio de una obligación recíproca por parte del comprador en caso de que el precio de referencia sea inferior al precio de ejercicio. De tal manera que tanto generador como comercializador aseguran la compra y la venta de energía por un determinado periodo de tiempo (días, meses, años, etc.).

Contrato de opciones y futuros: contrato normalizado a plazo, por el cual el comprador se obliga a comprar el activo subyacente y el vendedor a venderlo a un precio pactado (precio de futuro) en una fecha futura (fecha de liquidación). Hasta dicha fecha o hasta que se realice una transacción de cierre, se realizan las liquidaciones diarias de pérdidas y ganancias. Puesto que la liquidación del contrato puede realizarse por diferencias, la obligación de comprar y vender puede sustituirse en este caso por la obligación de cumplir la liquidación por diferencias.

Contratos bilaterales: son aquellos contratos en donde los acuerdos de compra y venta de energía que se establecen entre un generador y un consumidor cualificado o agente externo por el que el productor o generador se compromete a proporcionar unas determinadas cantidades de energía al consumidor a un precio acordado entre ambos.

Contratos a Plazos: (forward) son aquellos contratos en los cuales se pacta la compra y venta de energía en un tiempo determinado (futuro) a un precio determinado. En donde la negociación no se liga a ningún tipo de regulación de mercado (no estandarizado)

Mercado Intradiario: en el mercado intradiario se negocian cantidades adicionales para atender a los ajustes entre oferta y demanda posteriores a las transacciones dadas en el mercado diario. El cierre de ofertas coincide con los periodos que fueron asumidos y programados anteriormente en el mercado diario, y al tener los nuevos valores dados al nuevo cálculo intradiario, el ente operador realiza una programación de hora final, en donde los desvíos en despacho y generación son gestionados por dicho operador bajo procedimientos técnicos.

Mercado de Operación: en los mercados de operación se adaptan los programas de generación resultantes de los mercados diarios e intradiarios a las restricciones técnicas de la red de transmisión, para que el suministro se realice en condiciones de alta calidad.

Mercado diario (pool): es el mercado en el que se realizan las operaciones de ofertas de compra y venta de energía, allí los generadores realizan sus ofertas hasta completar la demanda, y aquellos con los precios inferiores al precio de despeje del mercado son despachados, en los siguientes numerales se explicara a profundidad.

2.2.3. Mercado de Energía Mayorista

[9] A partir de las leyes 142 y 143 se creó el ya mencionado mercado mayorista para el cual la CREG definió los alcances de este mercado y definió dos grandes sub mercados para las transacciones mayoristas.

Mercado Mayorista (MM), en dicho mercado participan los generadores, comercializadores y transportadores mayoristas, de tal forma que todos pueden ejercer el papel de vendedores y/o compradores.

Mercado Libre (ML), en donde los grandes consumidores son quienes toman el papel de compradores y sus vendedores son entonces los entes proveedores de electricidad.

[5][6][9] El esquema de organización del mercado colombiano se inspiró en la experiencia inglesa reciente. La bolsa de energía es un mercado para las 24 horas del día siguiente, con obligación de participación para todo generador registrado en el mercado, con reglas explícitas de cotización, y en el que la energía por contratos no queda denominada al precio spot. El lado de la demanda no participa directamente en la bolsa. La Bolsa se orienta a minimizar el costo del despacho, lo cual puede no coincidir con la maximización del bienestar de todos los agentes participantes. Los grandes consumidores no pueden acceder en forma directa al MM (mercado mayorista), ya que para hacerlo tendrían que constituirse como Empresas de Servicios Públicos -ESP- según lo dispuesto en la Ley. Sin embargo, pueden beneficiarse de las oportunidades de este mercado, ligando al comportamiento del mismo los acuerdos comerciales que realicen con los agentes económicos del MM.

2.2.4. Bolsa de energía en Colombia

[6][8] La bolsa de energía es un sistema de información utilizado para realizar transacciones de energía eléctrica entre agentes generadores y comercializadores, su manejo recae en el Administrador del Sistema de intercambios Comerciales (ASIC), quien ejecuta los contratos resultantes en la bolsa y de transporte y distribución.

La bolsa de energía cuenta con un mecanismo de formación de precios que se basa en las ofertas de precio y la declaración de disponibilidad de los generadores cada hora del siguiente día de operación, y en los pronósticos de demanda elaborados por el centro nacional de despacho (CND) y los operadores de red.

La bolsa de energía, es un mercado a corto plazo en donde los distribuidores y los generadores pueden negociar sus insumos como faltantes o excedentes por medio de contratos, este proceso se hace hora a hora en donde el precio es determinado por la oferta y la demanda y se le llama despacho eléctrico, ya que las empresas generadoras envían diariamente sus ofertas horarias para el día siguiente cumpliendo con la regulación propia del proceso y así reportando la disponibilidad y el precio de la energía.

[7] Ya que el CND (Centro Nacional de despacho) es el encargado de manejar la bolsa de energía además de la operación del SIN (Sistema Interconectado Nacional), con la información de disponibilidad reportada, construye una curva de oferta horaria, la cual se utiliza para despachar cada una de las plantas a medida que las condiciones del mercado y la demanda lo exijan, de esta forma se establece el ya mencionado proceso de despacho eléctrico.

En ella pueden participar todos los generadores a través de algún comercializador existente o creado por ellos, con una capacidad superior a los 20 MW localizados en un mismo sitio para el recibo de energía.

- Establecer y operar un sistema de transacciones de energía en bloque que entregue incentivos a las partes implicadas con el fin de que se produzca y se consuma de forma óptima la cantidad de energía que el consumidor demande.
- Suministrar las reglas que determinen las obligaciones y las solvencias financieras de los entes implicados debido a las transacciones de energía, a la participación en el mercado, al suministro de servicios complementarios, entre otros
- Establecer un mercado eficiente y competitivo.

Operación

[5] La operación se calcula teniendo en cuenta los precios monómicos de energía del día siguiente, los cuales reflejan el costo variable esperado de generación, antes de las 8:00 am los generadores entregan una oferta de precios para las 24 del día siguiente y expresado en \$/MWh (pesos por mega watt hora), para cada recurso de generación, además de entregar la disponibilidad esperada para cada hora y por cada unidad de generación expresada en MW, si no se presenta ofertas antes de las 8:00 am o se ha recibido información incompleta, se asumirá como oferta la última oferta valida.

Al tener las ofertas del día siguiente, el CND (Centro Nacional de Despacho) realiza un programa de despacho con el fin de satisfacer la demanda esperada para cada hora son utilizados los recursos que menor precio hallan ofertado y que cumplan con las condiciones límites del sistema, como los requisitos de reserva rodante, inflexibilidades de las planta s y las restricciones propias del sistema.

Antes de las 3:45 pm el CND envía el programa elaborado a los generadores para su aplicación al día siguiente. Durante el día se pueden presentar eventos inesperados que obliguen a ajustar el programa generado inicialmente, por lo que a este nuevo programa se le llama **re-despacho**. Algunos causantes del **re-despacho** pueden ser: el aumento de disponibilidad de generación por entrada de unidades en mantenimiento, cambios en la configuración de la red, cambios en los límites del sistema, salida de unidades de generación, entre otros.

2.2.5. Cálculo del Precio en Bolsa de Energía

[8] Se realiza a través del mercado spot mediante una subasta de precio en la cual los generadores realizan la oferta una sola vez con los precios para cada hora del día siguiente (deben tener la remuneración del cargo por confiabilidad), teniendo en cuenta la disponibilidad de energía.

La demanda por su parte, es representada por los comercializadores quienes cumplen la función de captar precios, es entonces que a partir de la disponibilidad de los generadores se realiza el despacho ideal, en donde son despachadas las ofertas de menor precio hasta completar o superar la demanda y el precio al que oferta; con este último equivalente al precio marginal son remunerados todos los generadores.

[1][5] El precio de bolsa horario (precio spot) se calcula de la siguiente forma:

- a. Se identifican todas las unidades de generación que presentan inflexibilidad (modificación de su disponibilidad durante la operación) con el fin de no tener en cuenta sus precios y así despreciar su oferta para el cálculo del precio en la bolsa de energía.
- b. Se tiene en cuenta el mayor precio de oferta de unidades con despacho centralizado que han sido programadas para generar en el despacho ideal y sin que presenten inflexibilidades.




FIGURA 4. Curva de Oferta (Demanda Vs Precio de Oferta)

Se tiene en cuenta entonces, la curva de oferta, y la disposición de los generadores ordenada de acuerdo al precio de menor a mayor, de modo que la cuando la curva de oferta y demanda se cruzan se genera el precio en Bolsa horario el cual está dado por la ultima unidad despachada para cubrir la demanda.

2.3. METODOS Y TECNICAS USADAS EN LA SOLUCION DEL PROBLEMA

2.3.1. Métodos Basados en Tratamientos Bayesianos

[11][12][13][14] Los métodos de regresión son modelos que permiten desarrollar una serie de lineamientos y parámetros para la predicción de valores de una variable numérica, con base en los valores de una o más variables diferentes. La variable dependiente es la que se desea predecir, y aquellas variables que se utilizan para dicha predicción son llamadas variables independientes; no obstante se puede encontrar aparte de los valores de la variable o variables dependientes, una función matemática que describa la relación entre las variables dependientes e independientes para una cuantificación de la incidencia que los cambios de las variables independientes tienen sobre las dependientes además de aportar información sobre observaciones inusuales.

En los últimos tiempos la predicción del precio spot de la energía eléctrica ha tomado un papel muy importante, ya que todas las partes que constituyen el “sistema eléctrico” de una región (país, ciudad, continente) se ven afectadas directa o indirectamente ante los cambios en los precios de la energía eléctrica. Durante décadas se han utilizado métodos de diferente naturaleza, los cuales buscan obtener características o patrones que describan el comportamiento de dicha variable.

Ya que la energía eléctrica tiene diversos factores que afectan su generación, transmisión y distribución, es apto mencionar, que los métodos que se plantean en este documento son métodos basados en variables no intrínsecas al proceso de

producción de electricidad, por lo que se basa en datos del pasado, lo que constituye una adhesión de los fenómenos de índole primaria, como lo son cambios atmosféricos, cambios y fenómenos climáticos, alza de otras divisas, inclusión del comportamiento de otros mercados (carbón, gas, emisiones... etc), lo que nos da una ventaja ya que al enfocar el estudio en los datos, estas variables están ligadas al valor de cada dato.

[4][15][16][17] Las máquinas de vectores de relevancia (RVM) son un tratamiento bayesiano de una función de decisión similar a la de una SVM, pero que no sufre de algunas de sus desventajas, y teniendo en cuenta que se basa en un método de aprendizaje supervisado en donde la estrategia que se utiliza convencionalmente es tomar aleatoriamente un subconjunto de la totalidad de pares observación-etiqueta para entrenar algún clasificador y los restantes para efectuar un proceso de validación.

Aunque son relativamente ralas, las SVM utilizan deliberadamente una cantidad arbitraria de funciones base, considerando que el número de vectores de soporte crece linealmente con el tamaño del conjunto de entrenamiento; además, se puede demostrar que el número de vectores de soporte es una cota superior del riesgo del clasificador.

En [4] es usado el método de Vectores de soporte de Relevancia para la predicción del precio spot de la energía eléctrica. En este caso se usan dos funciones Kernel, lo que lo convierte entonces en un método de multiregresión, ya que las dos máquinas de soporte de relevancia se usan para el mismo fin, sin embargo, las funciones kernel dan una serie de características a cada resultado, estas características son evaluadas, categorizadas y convertidas en un método de optimización el cual es resuelto con una técnica llamada (mGA) Micro Algoritmo Genético.

La mayor parte de los métodos econométricos se basan en la aplicación de técnicas estadísticas en las que, a partir de una muestra de datos, es preciso extrapolar o inferir los resultados de la modelización a una población mayor que la que ha generado la muestra.

2.3.2. Procesos Gaussianos para Regresión y Máquinas de soporte de relevancia

[3][4][15][16] Las máquinas de soporte vectorial (SVM) han sido usadas en diferentes aplicaciones tanto de regresión como de clasificación, sin embargo tienen varias limitaciones; por ejemplo y como caso particular las salidas de las SVM representan decisiones en lugar de probabilidades a posterior, entonces ya que las SVM fueron formuladas originalmente para dos clases, y la extensión de la variable k es mayor a 2 (clases $k > 2$), la formulación para esta extensión mayor de 2 clases aumenta su complejidad.

Así como para clasificación, en el caso de regresión existe un parámetro de complejidad E el cual puede ser encontrado usando un método de extensión, tal como validación cruzada; Finalmente las predicciones son expresadas como una combinación lineal de las funciones del kernel que se centran en los puntos de entrenamiento y que están definidas como positivas.

Las máquinas de soporte vectorial de relevancia o máquinas de vectores de relevancia vectorial (RVM) es una técnica bayesiana de kernel de dispersión para regresión y clasificación que comparte muchas de las características de las SVM evitando sus principales limitaciones, adicionalmente, proceden de modelos típicos de dispersión lo que aumenta la velocidad y el rendimiento en los resultados correspondientes a los datos de prueba, manteniendo al mismo tiempo la generalización del error comparable.

Las máquinas de vectores de relevancia para regresión es un modelo lineal que define una distribución condicional para una variable objetivo (t) de valor real, dado un vector de entrada x el cual tiene la forma

$$p(x, w, \beta) = N(t|y(x), \beta^{-1}) \quad (1)$$

Donde $\beta = \sigma^{-1}$ es la precisión de ruido (Varianza inversa de ruido) y la media está dada por un modelo lineal de la forma

$$y(x) = \sum_{i=1}^M w_i \phi_i(x) = W^T \phi(x) \quad (2)$$

Con funciones base $\phi_i(x)$, las cuales normalmente incluye un término constante y el cual corresponde al parámetro de peso que representa el sesgo de la función.

La regresión gaussiana es un caso específico de este modelo, con el cual se pretende reflejar la estructura de las máquinas de soporte vectorial, en particular las funciones base son dadas por kernels, con un kernel asociado a cada punto de los datos de entrenamiento, la expresión general para las máquinas de soporte vectorial (SVM) tiene la forma:

$$y(x) = \sum_{n=1}^N w_n k(x, x_n) + b \quad (3)$$

Donde b es el parámetro de sesgo, el número de parámetros en este caso es $M = N+1$, y $y(x)$ tiene la misma forma del modelo de predicción (1), exceptuando que los coeficientes a_n aquí son denotados como w_n , hay que destacar que el análisis subsiguiente es válido para elecciones arbitrarias de funciones base, y para generalidad se trabajara con la ecuación:

$$y(x) = \sum_{i=1}^M w_i \phi_i(x) = W^T \phi(x) \quad (4)$$

En contraste con las SVM, no hay ninguna restricción a los kernel definidos positivos, ninguna de las funciones base vinculada a los números o ubicación de los puntos de los datos de entrenamiento.

Debido a que no se puede obtener una expresión analítica para $p(w/t,a)$, se puede utilizar un procedimiento de aproximación laplaciano dados los valores actuales de los datos y así calcular los pesos más probables para el punto de localización de la distribución posterior, por lo tanto se recurre a encontrar el máximo sobre w de

$$\log \{P(t|w)P(w|a)\} = \sum_{n=1}^N [t_n \log y_n + (1 - t_n) \log(1 - y_n)] - \frac{1}{2} W' A W \quad (5)$$

Donde $y_n = \{\sigma(x_n, W)\}$ y $A = \text{diag}(\sigma_0, \dots, \sigma_N)$, dado que el método de laplace es una aproximación cuadrática del posterior logarítmico alrededor de su modo, el algoritmo procede a calcular repetidamente los hiperparámetros y las correspondientes actualizaciones de los gradientes y los pesos hasta que algún criterio de convergencia se satisfaga, cabe notar que nos necesario actualizar el parámetro de varianza.

En términos de un proceso gaussiano, se toman como base los términos de regresión lineal, de la forma $y(x, w) = w^T \phi(x)$ en donde w es un vector de parámetros y $\phi(x)$ es un vector de funciones base no lineales que dependen del vector de entradas (x), dado un conjunto de datos de entrenamiento se evalúa la distribución a posteriori sobre (w) por lo tanto se obtienen la correspondiente distribución a posteriori sobre las funciones de regresión, a su vez la adición de ruido implica una distribución predictiva $p(t/x)$ para el nuevo vector de entradas (x).

2.3.3. Series Temporales Basados en técnicas Econométricas de Medias Móviles

La econometría, que es el resultado de la adopción de una posición teórica de la economía, consiste en la aplicación de la estadística matemática a los datos económicos con el objetivo de proporcionar no solo un apoyo empírico a los modelos construidos por la economía matemática, sino una forma de obtener resultados numéricos. Un

modelo constituye una representación simplificada de la realidad, dicho modelo debe ser plausible y manejable, es decir, debe incorporar los elementos fundamentales de la situación que trata de modelizar, y de manera que las simplificaciones introducidas en él mismo permitan analizar y obtener sin dificultad conclusiones puntuales.

En razón de la finalidad para la que se elaboran, los modelos econométricos se pueden clasificar en: modelos explicativos, predictivos y modelos de decisión.

Explicativo: con los modelos explicativos se trata de captar cuantitativamente el mecanismo de funcionamiento, lo que supondrá la estimación de sus parámetros a partir de una muestra dada.

Predictivo: la finalidad inmediata de estos modelos es la obtención de pronósticos acerca de la evolución futura de las variables que constituyen el modelo.

Modelos de decisión: son aquellos modelos en los cuales se involucran variables sobre las cuales se pueda tener una influencia directa y así tener control sobre el modelo de forma inmediata o casi instantánea, estas variables también son llamadas variables instrumentales.

[1][2][10] El modelo ARIMA se compone de dos sub modelos y por lo tanto comparte sus características, una parte es el auto regresivo o de memoria larga, en la cual el valor actual (presente) de la o las variables se representan en función de su pasado más un bias o innovación, y la parte de medias móviles en donde el valor presente de la o las variables se representan en función de todas las innovaciones (bias), las cuales pueden ser pasadas o presentes. La mayor ventaja de este modelo es que sin importar la naturaleza de los datos, su estructura se basa en media cero, varianza constante finita y una función de auto covarianzas infinita por lo que la función de auto correlación entre las variables decrece rápidamente hasta cero sin truncarse, para efectos de minimizar tiempo de cómputo. Como dificultad operativa en este problema en específico se utiliza una modelación ARIMA para tratamiento de datos de naturaleza estocástica ya que es uno de los métodos econométricos más usados y fiables para este tipo de casos.

En general se han utilizado diversos tipos de métodos para solucionar problemas de naturaleza similar en [1][13] se observa una moldeamiento SARIMAX (Seasonal ARIMA Whith Exogenous Variables) en donde la base del tratamiento de los datos estocásticos es dada por un modelo autor regresivo integrado de medias móviles con un polinomio auto regresivo de orden p y otro de medias móviles de orden Q los cuales tienen una tendencia estacional, este término estacional se entiende como una pauta del comportamiento cíclico en el conjunto de características en un periodo de tiempo, lo que implica una regularidad en el comportamiento particular de una serie, por lo que se pueden ver cambios de niveles bruscos, pero sin embargo a través del tiempo algunos patrones se repiten; además de esto se adiciona un parámetro externo al modelo (exógeno) de orden $t-h$ el cual suma un grado dimensional más al conjunto de innovaciones intrínsecas al método base.

En [3] se tienen como punto de comparación dos métodos de naturaleza diferente, ya que uno es un método econométrico basado en un modelo estadístico ARIMA (anteriormente mencionado) y por otro lado un método inteligente ANN (red neuronal artificial), en donde se busca inferir sobre el precio de la energía eléctrica en el mercado eléctrico iraní, se tomaron datos durante un periodo de aproximadamente 28 días (un mes) contados por horas y se estimó el precio de las próximas 24 horas usando dos modelos temporales, llamados uno de 24 horas y el otro de una hora, a partir de los resultados obtenidos se deduce que el modelo de 24 horas usando una ANN es más preciso, sin embargo la ventaja más sobresaliente de la serie econométrica es la utilización de pocos datos y tiempo de cómputo para la solución del problema por lo que nuestro punto de comparación es aceptable.

2.3.4. Modelos AR (Modelo estocástico Autor regresivo) de Primer Orden

[2][20][21][10] El proceso regresivo de orden p AR (1) es una aproximación natural al modelo lineal general

$$y_t = \pi_1 y_{t-1} + \pi_2 y_{t-2} + \pi_3 y_{t-3} + \dots + a_t \quad \forall t \quad t = 1, 2, \dots \quad (6)$$

El valor presente de la variable se representa en función de su propio pasado más una innovación contemporánea, en este proceso, la variable Y_t viene determinada únicamente por su valor pasado Y_{t-1} y la perturbación contemporánea a_t , se identifica entonces una estructura de correlación tanto para el valor pasado como para su perturbación, es decir, la perturbación a_t entra en el sistema en el momento t e influyendo en y_t y en su futuro, pero no en su pasado.

El proceso estocástico auto regresivo siguiendo los lineamientos propios y cumpliendo con las condiciones generales (no anticipante e invertible) debe cumplir además las condiciones de estacionariedad.

a) La estacionariedad en media se da cuando la media de una función es constante y finita, lo que implica, que:

$$E(Y_t) = \phi E(Y_t) \rightarrow (1 - \phi)E(Y_t) = 0 \rightarrow E(Y_t) = \frac{0}{1 - \phi} = 0 \quad (7)$$

Entonces para que cumpla la condición de estacionariedad el parámetro $\frac{0}{1 - \phi}$ sea diferente de 1.

b) Estacionario en covarianza, para cumplir esta condición, la varianza ha de ser constante y finita

$$\gamma_0 = E(Y_t - E(Y_t))^2 \quad (8)$$

$$\gamma_0 = E(\phi Y_{t-1} + a_t - 0)^2 \quad (9)$$

$$\gamma_0 = \phi^2 E(Y_{t-1})^2 + E(a_t)^2 + 2\phi E(Y_{t-1} a_t) \quad (10)$$

Dada la estructura de auto correlación del proceso y bajo el supuesto de que el proceso es estacionario

$$E(Y_{t-1}a_t) = E[(Y_{t-1} - 0)(a_t - 0)] \quad (11)$$

Entonces

$$\gamma_0 = \phi\gamma_0 + \sigma^2 \rightarrow (1 - \phi)\gamma_0 = \sigma^2 \rightarrow \gamma_0 = \frac{\sigma^2}{1 - \phi^2} \quad (12)$$

Y para que esto se cumpla $|\phi| < 1$, Si se tiene en cuenta la suposición de que el proceso es no anticipante, es decir el futuro no influye en el pasado

La función de auto covarianzas de un proceso AR estacionario es

$$\gamma_0 = \begin{cases} \frac{\sigma^2}{1 - \phi^2} & k = 0 \\ \phi\gamma_{k-1} & k > 0 \end{cases} \quad (13)$$

Por lo tanto, si el parámetro autor regresivo es $|\phi| < 1$, la varianza es finita y el resto de las auto covarianzas también lo son, y además dependen únicamente de los periodos de separación entre las variables y no del tiempo, por lo que el proceso es estacionario.

Dado que para procesos estacionarios el parámetro en valor absoluto es menor que la unidad, la función de auto correlación decrece exponencialmente con k, es decir se va aproximando a cero conforme k crece, pero no llega nunca a valer cero.

2.3.5. Modelo Autor regresivo Integrado de Media Móvil (ARIMA)

[1][2][20] Son modelos paramétricos con los cuales se trata de obtener la representación de la serie en términos de la interrelación temporal de sus elementos, este tipo de modelos caracterizan las series como sumas o diferencias ponderadas y no ponderadas, de variables aleatorias o resultantes.

Como parte fundamental para el desarrollo de series temporales en términos de la interrelación de sus observaciones es el denominado coeficiente de auto correlación, que mide la correlación lineal existente entre observaciones separadas por N periodos, este coeficiente proporciona información sobre cómo están relacionados entre s las observaciones lo cual es fundamental a la hora de modelar un conjunto de datos en forma de una serie temporal.

El coeficiente de correlación entre dos variables X_i o Y_i, p_{xy} , se define como:

$$p_{xy} = \frac{\text{cov}(x, y)}{\sqrt{V(x)V(y)}} \quad (14)$$

Este coeficiente no tiene unidades por definición y toma valores de

$$-1 \leq p_{xy} \leq 1 \text{ si } p_{xy} = 0 \quad (15)$$

No existe relación lineal entre x e y. Si $p_{xy} = 1$, existe relación lineal perfecta y positiva entre x e y si $p_{xy} = -1$, existe relación lineal perfecta y negativa entre x e y.

El coeficiente de correlación se puede utilizar como instrumento para analizar la estructura de correlación existente entre las observaciones de una serie temporal Y_t .

Partiendo de la suposición del modelo ARMA (p,q):

$$\emptyset_p(L)Y_t = \Theta_q(L)a_t \quad (16)$$

Cuyo polinomio AR es factorizable en función de sus p raíces L_1, L_2, \dots, L_p ,

$$\phi_p(L) = (1 - L_1^{-1}L)(1 - L_2^{-1}L) \dots (1 - L_p^{-1}L) \quad (17)$$

Suponiendo que $(p-1)$ raíces son estacionarias (con modulo fuera del circulo unidad) y una de ellas es unitaria, $L_i=1$, entonces, el polinomio AR, se puede reescribir como:

$$\phi_p(L) = (1 - L_1^{-1}L)(1 - L_2^{-1}L) \dots (1 - L_{p-1}^{-1}L) = \phi_{p-1}(L)(1 - L) \quad (18)$$

$$\phi_p(L) = \phi_{p-1}(L)(1 - L) \quad (19)$$

Donde el polinomio $\phi_{p-1}(L)$ resulta del producto de los $(p-1)$ polinomios de orden 1 asociados a las raíces L_i con módulo fuera del circulo unitario.

En general, el polinomio AR puede contener más de una raíz unitaria, por lo tanto, se puede descomponer como:

$$\phi_p(L) = \phi_{p-1}(L)(1 - L)^d \quad (20)$$

Y sustituyendo, de nuevo, en el modelo ARMA (p,q) se tiene:

$$\phi_{p-1}(L)\Delta^d Y_t = \theta_q(L)a_t \quad (21)$$

Siendo el polinomio $\phi_{p-d}(L)$ estacionario por que su $(p - d)$ raíces tienen modulo fuera del circulo unitario, y el polinomio $\Delta^d = (1 - L)^d$, de orden d , contiene las d raíces unitarias no estacionarias. A un proceso con estas características se le denomina proceso integrado de orden d .

2.3.6. Métodos de Optimización exacta

[12][13][14] Las técnicas de optimización son utilizadas para encontrar los valores de los parámetros de un conjunto de datos las cuales maximizan o minimizan algunas funciones objetivo de interés, estos métodos adquieren gran importancia frente a análisis estadísticos para estimación, en la formulación y adecuación de modelos para problemas de aplicación, entre otros.

Los métodos de optimización se pueden clasificar en los siguientes:

2.3.6.1. Métodos analíticos

Emplean las técnicas clásicas de cálculo diferencial, estos métodos buscan los extremos de una función mediante valores de una variable que hacen que su derivada con respecto a esa misma variable sea cero. Si la función tiene además restricciones, se deben de utilizar técnicas tales como multiplicadores de Lagrange. Estos métodos no suelen ser apropiados para la mayoría de problemas no lineales.

2.3.6.2. Los métodos numéricos

Usan información pasada para generar una mejor solución del problema a optimizar por medio de procedimientos iterativos.

2.3.6.3. Métodos Gráficos

Consisten en preparar una gráfica de la función a optimizar. El extremo de la función se obtiene por inspección directamente de la gráfica, estos métodos tienen la ventaja de ser elementales y de revelar fácilmente se existe o no la solución. Sin embargo, están restringidos al criterio de una o dos variables independientes.

2.3.6.4. Métodos experimentales

El extremo de una función se puede obtener por experimentación directa de las variables del proceso real. Los resultados de un experimento se usarán para decidir donde situar el siguiente experimento y así poder lograr mejores resultados.

Dentro de las categorías mencionadas anteriormente también existen subdivisiones, y en el caso las técnicas de optimización no lineal se pueden subdividir en tres clases principales:

Métodos de búsqueda unidimensional:

Estos métodos se basan en un proceso iterativo para encontrar el valor óptimo utilizando dos tipos de procedimientos, métodos de eliminación o de aproximación.

Métodos de optimización sin restricciones:

Los métodos sin restricciones se subdividen a su vez en dos tipos, métodos de búsqueda directos e indirectos (descendientes)

2.3.7. Mínimos Cuadrados

[11][23] Es un método numérico para con el cual se calcula un modelo analítico de datos generalmente ruidoso, el procedimiento se utiliza para calcular los parámetros del modelo a partir de los datos medidos.

Asumiendo las mediciones de una variable dependiente conjugarlas en función de una variable independiente, en donde el modelo se ajusta a los datos medidos teniendo en cuenta la siguiente suposición:

$$y = f(x) + \varepsilon \quad (22)$$

x siendo una variable independiente, Y una variable dependiente y (ε) ruido blanco,

Asumiendo un conjunto de mediciones recolectadas y suponiendo una relación como ejemplo práctico de forma lineal entre la variable independiente X y variable dependiente Y así el modelo

$$y = aX + b \quad (23)$$

Podría estar equipado con exactitud en presencia de ruido o la variabilidad en los datos.

Para más detalle, [23] dada una variable bidimensional (X, Y) que toma valores (X_i , Y_i) con frecuencias n_{ij} , $i=1, \dots, k$, $j=1, \dots, m$, la nube de puntos que representa su distribución nos permite decidir cuál puede ser la forma de la función que ajusta esos datos. Esa función genérica dependerá de una serie de parámetros desconocidos y nuestro objetivo será obtener, a partir de los datos disponibles, una estimación de esos parámetros de manera que esa función obtenida sea la que mejor aproxime las observaciones.

Así, para cada valor observado de la variable independiente X (X_i) podemos considerar dos valores de la variable dependiente Y: el valor observado Y_i y el valor teórico Y_{ii} que se obtiene mediante la función de ajuste.

La diferencia entre el valor observado y el valor teórico recibe el nombre de error o residuo que denota y proporciona la equivocación cometida al estimar mediante la función de ajuste de la variable Y correspondiente X_i .

Teniendo en cuenta las necesidades frente a los constantes cambios en el sistema eléctrico colombiano durante las últimas décadas. Se ve la necesidad de implementar técnicas para la solución de problemas tales como el sobre dimensionamiento de las redes eléctricas, la producción excesiva de energía, los gastos innecesarios por pérdidas técnicas y no técnicas, para el caso en particular tratado en este documento, se da paso hacia la solución de éstos, ya que al tener claro el precio spot del sistema se puede discernir sobre el resto de variables que intervienen en el proceso de generación, transmisión y distribución de la energía eléctrica.

Según el modelo ya mencionado, técnicas econométricas han sido aplicadas para la solución de estos problemas, a continuación, se enunciarán algunos de estos métodos.

2.3.8. Método de Validación Cruzada Holdout

[18][24] El método de validación cruzada, es un enfoque clásico para la estimación y representación generalizada de modelos de aprendizaje de máquina, al usar el método Holdout se separa el conjunto de datos iniciales dentro de un grupo de datos de entrenamiento y testeo o prueba, el primer conjunto es usado como conjunto de datos de entrenamiento, y el segundo grupo es usado como conjunto de validación, el cual sirve para estimar su rendimiento. Sin embargo, en aplicaciones típicas de aprendizaje, el interés se centra en la sintonización y comparación de diferentes configuraciones de parámetros para mejorar su rendimiento y estimar los datos desconocidos. Este proceso se llama selección de modelo, donde el término selección de modelo se refiere a un problema de clasificación para el cual queremos seleccionar los valores óptimos de los parámetros de ajuste (también llamados hiperparámetros). Sin embargo, si reutilizamos el mismo conjunto de datos de prueba una y otra vez durante la selección del modelo, se convertirá en parte de nuestros datos de entrenamiento y por lo tanto, será más probable que el modelo se sobre entrene.

Una mejor manera de utilizar el método Holdout para la selección del modelo es separar los datos en tres partes: un conjunto de entrenamiento, un conjunto de validación y un conjunto de prueba. El conjunto de entrenamiento se utiliza para adaptarse a los diferentes modelos, y el rendimiento en el conjunto de validación se utiliza para la selección del modelo. La ventaja de

tener un conjunto de prueba que el modelo no ha visto antes durante el entrenamiento y selección del modelo es que podemos obtener una estimación menos sesgada de su capacidad para generalizar a nuevos datos. En la figura 5 se ilustra el concepto de validación cruzada Holdout, donde usamos un conjunto de validación para evaluar repetidamente el rendimiento del modelo después del entrenamiento con diferentes valores de parámetros. Una vez que estamos satisfechos con el ajuste de los valores de los parámetros, estimamos el error de generalización de los modelos en el conjunto de datos de prueba:

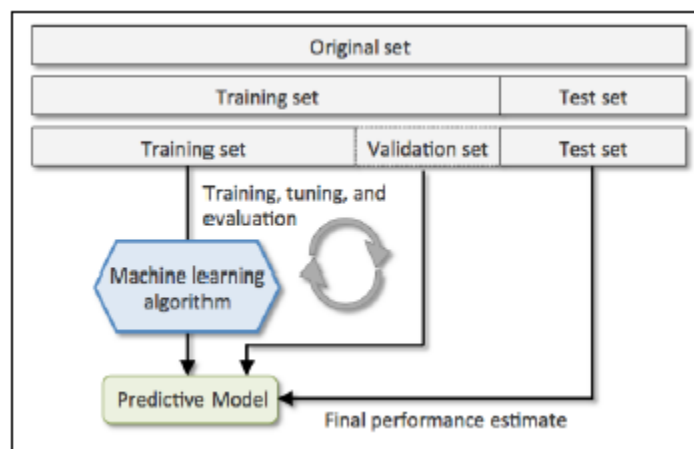


FIGURA 5. Validación Cruzada Hold Out

2.3.9. Mínimos Cuadrados Regularizados Con Representación No Lineal.

[19][25][26] Diferentes modificaciones han sido implementadas al método de mínimos cuadrados para la solución de problemas lineales y no lineales, con la finalidad de resolver y encontrar las variables indirectas por medio de la minimización de funciones; sin embargo, todas las soluciones han tenido ciertas limitaciones además de su sensibilidad a pequeñas variaciones de los datos observados. Una limitación obvia ocurre cuando el conjunto de matrices inversas de la forma $(A^T A)^{-1}$ o $(A^T W^2 A)^{-1}$ no existen o no son posibles. Sin embargo, incluso si dichas matrices inversas existieran, éstas pueden ser condicionadas (en caso de singularidades). En este caso la solución será extremadamente inestable e irreal. Por lo anterior se ha optado por aplicar métodos regularizados.

Las correspondientes variables paramétricas pueden ser introducidas de la siguiente manera:

$$Y(\hat{X}) = \Phi_1(\hat{X})^T w^* \quad (24)$$

Donde $Y(\hat{X})$ y \hat{X} son algunos matices de ponderación de datos y modelo (no necesariamente diagonal); w es un modelo a priori y denota la norma euclidiana en el espacio de datos y modelos.

Siendo entonces la función de error a minimizar la siguiente:

$$e(w) = \sum_{i=1}^N (y_i - \Phi(x_i)^T w)^2 + \lambda \sum_{j=1}^p \|w\|^2 \quad (25)$$

Se puede también re escribir la variable $e(w)$ en la siguiente notación matricial:

$$(\Phi(x_i)^T \Phi(x_i) + \lambda I)w - \Phi(x_i)^T y_i = 0 \quad (26)$$

En donde se relaciona el vector de pesos con distribución a priori y los datos de entrada:

$$(\Phi(x_i)^T \Phi(x_i) + \lambda I)^{-1} \Phi(x_i)^T y_i = w \quad (27)$$

En donde se obtiene la solución regularizada al problema generalizado de mínimos cuadrados al reemplazar los valores de hiperparámetros en la función inicial y de esta manera obtener una distribución a posteriori a partir de los datos de entrada.

2.3.10. Método de regresión usando modelo de kernel rígido

[27][28][29][35] El método de regresión por kernel Rígido (KRR) es basado en una función kernel regularizada por medio de un enfoque llamado “Kernel Trick”, el cual le permite operara en un espacio de características implícitas de alta dimensionalidad sin calcular las coordenadas de los datos en dicho espacio, sino simplemente calcular los productos internos entre las imágenes de todos los pares de datos en el espacio de características, ésta operación suele ser computacionalmente más sencilla que el cálculo explícito de las coordenadas.

$$Y(\hat{X}) = \phi_1(\hat{X})^T w^* \quad (28)$$

Donde se asume que la función pasa por el origen sin ser una intersección necesaria, esto implica un coeficiente λw para cada instancia de entrenamiento, donde λw abarca todos los casos en los datos de entrenamiento.

Es allí donde entra en juego el termino Kernek Rigido, ya que, en vez de minimizar la perdida al cuadrado, se intercambia la proximidad de ajuste contra la complejidad del modelo introduciendo un término llamado “penalidad”.

$$e_{Ridge}(w) = \frac{1}{2} \sum_{i=1}^N (y_i - \phi(x_i)^T w)^2 + \frac{\lambda}{2} \sum_{j=1}^p \|w\|^2 \quad (29)$$

[28] Se calcula el gradiente de $e_{Ridge}(w)$ con respecto a w e igualamos a cero, la segunda suma penaliza los grandes coeficientes, lo que evita que el modelo se sobre entrene, y entregando grandes coeficientes a menos que esto produzca una desviación muy grande en el error y se tiene la siguiente expresión:

$$w = \sum_{i=1}^N -\frac{1}{\lambda} (w^T \phi(x_i) - y_i) \phi(x_i) = \Phi^T a \quad (30)$$

El parámetro λ controla la compensación entre la cercanía de ajuste y complejidad del modelo, cuando se utilizan operaciones matriciales para resolver los coeficientes del modelo, la penalización rígida también tiene el beneficio adicional de estabilizar la función, y al reemplazar w en e_{Ridge} :

$$e_{Ridge}(a) = \frac{1}{2} \sum_{i=1}^N (a^T \Phi \phi(x_i) - y_i)^2 + \frac{\lambda}{2} a^T \Phi \Phi^T a \quad (31)$$

Definiendo K como una distribución

$$K = \Phi \Phi^T \quad (32)$$

Reemplazando y calculando el gradiente con respecto a (**a**)

$$\mathbf{a}^* = (\mathbf{K} + \lambda \mathbf{I}_N)^{-1} \mathbf{y} \quad (33)$$

Reemplazando los valores óptimos en el modelo de regresión se tiene:

$$Y(\hat{X}) = \phi_1(\hat{X})^T \mathbf{w}^* = \phi_1(\hat{X})^T \Phi^T \mathbf{a}^* \quad (34)$$

En comparación con otros enfoques usados a métodos de regresión, este método no ignora los errores más pequeños y el error cuadrático es usado en vez del error absoluto y su regularización permite atenuar el ajuste excesivo manteniendo los coeficientes de regresión lo más pequeños posibles.

2.3.11. Kernel de Filtro Adaptativo

[29][30][41] Los métodos de kernel, son una poderosa herramienta de modelado no paramétrico, su principal idea es transformar los datos de entrada en un alto espacio de características tridimensionales a través de un kernel, de manera que la operación de su producto interno en el espacio de características se puedan calcular de manera eficiente a través de la evaluación del kernel, entonces los apropiados métodos lineales son posteriormente aplicados sobre los datos transformados, por lo tanto si un algoritmo puede ser formulado en términos de su producto interno, no es necesario realizar cálculos en espacios de alta dimensionalidad, por lo que se debe mencionar la importancia del uso de los datos dentro del espacio de Hilbert o algún espacio que cumpla con dicho propósito, el cual juega un papel central en el suministro de linealidad, convexidad y aproximación universal.

Un filtro adaptativo, es una estructura de filtro conformada por un algoritmo adaptativo no lineal, el cual adapta y sintoniza su función de transferencia a los cambios en las propiedades de los datos de entrada a través del tiempo, buscando minimizar una función de error la cual indica que tan desviado se encuentra la respuesta del filtro al comportamiento.

El filtrado adaptativo usando kernel tiene como objetivo resolver una serie de problemas convexos de mínimos cuadrados (LS), muchos de estos filtros pueden obtenerse aplicando un filtro adaptativo lineal directamente a los datos transformados (Figura 6).

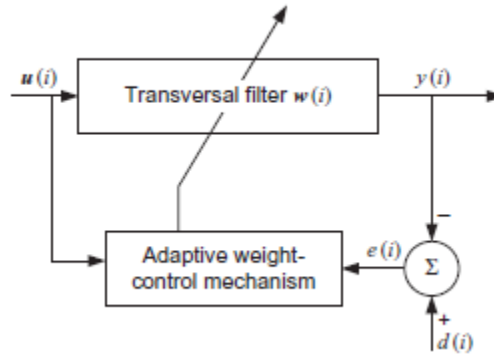


FIGURA 6. Estructura Básica de Filtro Adaptativo Lineal

Lo anterior requiere la reformulación de productos basados en la operación de productos escalares en términos de las evaluaciones del kernel, los algoritmos resultantes generalmente consisten en expresiones algebraicas simples, aunque con una potente capacidad de filtrado no lineal.

El filtro incorpora una conjunto de parámetros ajustables, que se denota por el vector $w(i-1)$, donde (i) denota una fracción de tiempo discreto, un vector de entrada $u(i)$ aplicado al filtro en el tiempo (i) , produciendo una respuesta $y(i)$, esta respuesta se compara con una respuesta deseada $d(i)$ para producir la señal de error $e(i)$, la señal de error es utilizada para ajustar el vector de parámetros $w(i-1)$ del filtro en una cantidad incremental $\Delta w(i)$

$$w(i) = w(i - 1) + \Delta w(i) \quad (35)$$

En la siguiente iteración $(i+1)$, $w(i)$ se convierte en el ultimo valor del vector de parámetros a ser actualizado, este proceso se repite hasta alcanzar una condición y en donde secuencialmente el los ajustes al vector de parámetros van disminuyendo hasta detener la adaptación.

La adaptación se consigue minimizando el error cuadrático medio entre la señal de salida y la señal deseada:

$$J(i) = \sum_{j=1}^i [d(j) - w^T u(j)]^2 \quad (36)$$

Siendo el error de predicción

$$e(i) = d(i) - w^T(i-1)u(i) \quad (37)$$

La nueva información es proporcionada al algoritmo en el tiempo (i) por el vector de entrada y respuesta deseada $\{u(i), d(i)\}$ y la predicción del error se conoce como innovación, el ajuste suministrado a la antigua estimación $w(i-1)$ se define por

$$\Delta w(i) = k(i) e(i) \quad (38)$$

$k(i)$ es el vector de ganancia

$$k(i) = P(i)u(i) \quad (39)$$

Donde $P(i)$ es el estado de errores de la matriz de correlación, siendo la inversa del promedio de la matriz de correlación $R(i)$, del vector de entrada $u(i)$

$$P(i) = R^{-1}(i) \quad (40)$$

De acuerdo a la formulación anterior se tiene entonces

$$\underbrace{w(i)}_{\text{Updated estimate}} = \underbrace{w(i-1)}_{\text{Old estimate}} + \underbrace{k(i) e(i)}_{\text{Adjustment}} \quad (41)$$

2.4. BIBLIOGRAFÍA

- [1] Mengchen Xie, Claes Sandels, Kun Zhu, Lars Nordstrom, “A Seasonal ARIMA Model With Exogenous Variables for Elspot Electricity Prices in Sweden”, 10th International conference on the European Energy Market, 2013
- [2] María Pilar Gonzales, “Análisis de series Temporales Modelos ARIMA”, UPV-EHU, España 2009.
- [3] Rueda Viviana Marì, Velazques Henao Juan David, Cardona Franco Carlos Jaime, ”Avances Recientes En La Predicción De La Demanda De Electricidad Usando Modelos No Lineales”, Universidad Nacional de Colombia, 2011.
- [4] Miltiadis Alamaniotis, Andreas Ikononopoulos, Aggelos Alamaniotis, Dimitrios Bargiotas and Lefteri H. Tsoukalas, “Day-ahead Electricity Price Forecasting using Optimized Multiple-Regression of Relevance Vector Machines”, 8th Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion MEDPOWER 2012.
- [5] Stacchetti, E. “Auction Design for the Colombian Electricity Market”, Universidad de Chile, Noviembre, 1999].
- [6] Rubén D. Cruz Rodríguez, Horacio Torres Sánchez, Otros “Caracterización del Sector Eléctrico Colombiano”, Servicio Nacional de Aprendizaje, Medellín 2013.
- [7] Jaime Millan, Entre el Mercado y el Estado, Departamento de Desarrollo Sostenible (BID), Washington 2006.
- [8] Melo Ligia, Espinosa Nestor, “Costo de la Ineficiencia en el Mercado de Energía Mayorista de Colombia”, Colombia 2014.
- [9] Fainboim Yaker Israel, Rodríguez Restrepo Carlos Jorge. El desarrollo de la Infraestructura en Colombia en la Década de los Noventa Tomo 1. Colombia. 2000.
- [10] Ahad Esmaili K., Mehrdad Eghlimi and Zijun Zhang, Forecasting the Electricity Price in Iran Power Market: A Comparison between Neural Networks and Time Series Methods.

- [11] Hartley Richard and Zisserman Aandrew, Multiple Geometry in Computer Vision, Cambridge, United Kingdom, 2004.
- [12] Jao Manuel R.S Tabares, R.M Natal Jorge, Advances in Computational and Medical Image Processing, Springer, Porto Portugal 2009
- [13] B.S. Everitt An introduction to Optimization Methods and their Application in Statistics, Chapman and Hall, London 1987.
- [14] David de la fuente García, Paolo Priore moreno, “Programación Lineal Entera y Programación no Lineal”, Universidad de Oviedo, España 1996.
- [15] Henao Ricardo, Sanz Jorge Humberto, Duque Edison, Aprendizaje Activo Para Maquinas de Vectores de Relevancia, Scientia et Technica, Colombia 2006.
- [16] Christopher M. Bishop bishop, Pattern Recognition and Machine Learning, Springer, USA, 2006.
- [17] Herbrich, Ralf, “Learning Kernel Classifiers”.MIT Press, Massachusetts of technology, USA 2002.
- [18] Sebastian Raschka, “Python Machine Learning”, Packt Publishing Ltd, UK 2015.
- [19] Richard C. Aster, Brian Borchers, Clifford H. Thurber Parameter Estimation and Inverse Problems, Elsevier, USA 2013.
- [20] J.M. Caridad y Ocerin, “Econometria Modelos Econometricos y Series Temporales”, Reverté, España 2005.
- [21] Jibo Chen, Xiaorong Huang, Jie Li, Guizhi Wang, Prediction of Energy Consumption in Jiangsu Based on Combination Model, Third International Conference on Information and Computing, 2010.
- [22] Flores López Raquel, Fernández Fernández Jose M, “Las Redes Neuronales Artificiales”, Netbiblo, S.L, España 2008.
- [23] Roberto Pérez, Covadonga Caso, María de Jesús Rio y Ana Jesús López, Introducción a la Estadística Económica, Universidad de Oviedo, Abril 2012.

- [24] William L Fehlman, Mobile Robot Navigation with Intelligent Infrared Image Interpretation, Springer, USA 2009.
- [25] Michael S. Zhdanov, Geophysical Inverse Theory and Regularization Problems, Elsevier, USA 2002.
- [26] Guy Chavent, Nonlinear Least Squares for Inverse Problems, Springer, París, 2009.
- [27] Sergios Theodoridis, “Machine Learning_ A Bayesian and Optimization Perspective”, Elsevier, UK 2015.
- [28] Ian H. Witten, Eibe Frank, Mark A. Hall, Data Mining Practical Machine Learning Tools and Techniques, Third Edition Elsevier, USA 2011.
- [29] Jose Luis Rojo Alvarez, “Digital signal processing with Kernel Methods”, John Wiley & Sons, Inc, USA 2018.
- [30] Weifeng Liu, José C. Príncipe, and Simon Haykin, “Kernel Adaptive Filtering a Comprehensive Introduction”, John Wiley & Sons, Inc, New Jersey 2010.
- [31] Sabina Carpellini, Alfonso Aranda Uson, Ignacio Zabalza Bribian “Introducción a los mercados energéticos”, Universidad de Zaragoza, España 2008.
- [32] Hang T, Nguyen and Ian T. Nabney, “Energy Forward Price Prediction with Hybrid Adaptive Model”, IEEE Symposium on computational Intelligence for Financial engineering, 2009
- [33] Patrima Kumari, Rajesh Wadhvani, “Wind Power Prediction Using KLMS Algorithm”, IEEE International Conference on Inventive Research in Computing, ICIRCA 2018.
- [34] Fabrizio Argenti, Bassam Bamieh, Laura Giarré, “Regularized LMS Methods for baseline wandering removal in wearable ECG devices”, IEEE 55th Conference on Decision and Control, 2016.
- [35] Dorronsoro Iberio, José Ramon, “Procesos Gaussianos para problemas de regresión y estimación de la incertidumbre”, UAM, Madrid 2018.
- [36] Alberto Muñoz, Urquijo Jaime, Castro Anibal Lombana Jahir, Pronóstico del precio de la energía en Colombia utilizando modelos arima con igarch, Universidad del Rosario 2017.
- [37] Velasquez Juan David, Franco Carlos, Garcia Hernan, “Un modelo no lineal para la predicción de la demanda mensual de electricidad en Colombia”, UNAL, 2009
- [38] Fouzi Douak, Farid Melgani, “Kernel ridge regression with active learning for wind speed prediction”, ELSEVIER 2012.

[39] Rosario Espínola, “Predicción A Corto Plazo De Los Precios De La Energía Eléctrica”, Universidad de castilla, España 2004.

[40] De la Pompa Porras Victor, Procesos Gaussianos para Problemas de Regresión y Estimación de la Incertidumbre, UAM, Madrid 2018.

[41] Weifeng Liu, José C. Principe, Simon Haykin, “Kernel Adaptive Filtering”, Wiley, USA 2010

[42] Mayorga Ricardo Andres, Piñeros Luis Felipe” Propuesta de un Modelo con Redes Neuronales y Metodología Box & Jenkins para el Pronóstico del Precio de Bolsa de la Energía en Colombia

CAPITULO 3

El capítulo 3 consta del desarrollo técnico de resultados de los modelos y métodos utilizados para la solución del problema.

3. RESULTADOS

3.1. Introducción

En el presente capítulo, se llevará a cabo la aplicación, y sustentación de las técnicas mencionadas en capítulos anteriores, con el fin de proporcionar la aproximación necesaria a un modelo que describa el comportamiento de los datos (ANEXO 1), teniendo como finalidad la predicción del precio spot de la energía eléctrica en el sistema eléctrico colombiano.

Es necesario tener en cuenta la naturaleza de los datos de estudio, en donde se dispondrá de una variable que depende intrínsecamente a los cambios en la función principal, que refleja la variación del precio spot; en donde las variables que afectan la fluctuación están inmersas en el registro de datos, lo que nos proveerá gran ventaja a la hora de analizar la información.

Los datos utilizados son suministrados por la Unidad de Planeación Minero Energética (UPME) en donde se recolecta la información del precio en bolsa de energía eléctrica desde el año 2002 hasta 2016 <http://www.upme.gov.co/Reports/Default.aspx?ReportPath=%2fSIEL+UPME%2fIndicadores%2fIndicadores+Bolsa&ViewMode=Detail>

En ambos casos, las características de los datos son iguales, sin embargo, cada metodología de solución transforma la información para ajustar el modelo de predicción al modelo real, sin alterar la información intrínseca de cada dato o la naturaleza de su realización.

Los datos descritos, son valores del precio de la energía en bolsa, tomando cada uno de los días de los meses del año, durante los años mencionados anteriormente; debido a los factores que afectan la obtención y capitalización de dicho precio en la bolsa energética colombiana, su naturaleza es estocástica, y su fluctuación es altamente aleatoria y para el caso de estudio, se trata de una variable discreta cuya serie es univariante, ya que su análisis se hace en función de su propio pasado.

3.2. Modelación ARIMA

En el siguiente ejemplo, se dispone de un modelo de predicción ARIMA, en donde se tabula una serie de datos con características iguales a las descritas en numerales anteriores para la predicción del precio spot de energía eléctrica en la bolsa de energía colombiana, los datos utilizados son de naturaleza estocástica.

Para el primer punto de predicción, se toma el dato número 147, el cual es representado por el punto de coloración verde y que en el modelo de predicción arroja un valor de 263,08 \$, este valor se compara con el dato real 262,8, lo que nos da una diferencia de 0,28 y un error de 0,10%.

En las Figuras 7 y 8 se muestran los siguientes parámetros: punto de predicción (punto color verde), línea de seguimiento (línea color azul) y la línea conformada por los datos reales (línea color Rojo)




FIGURA 7. Visualización dato de predicción para el día 147




FIGURA 8. Visualización dato de predicción para el día 147

A continuación, se muestra la función de auto correlación en función de la serie no estacionaria en donde sus valores tienden a cero con un decrecimiento lento, es por ello que se hace necesario aplicar una diferenciación de orden 1 para la serie (Figura 9).




FIGURA 9. Función de Autocorrelación vs Retardo

En la Figura 10, se muestra el resultado de la función de auto correlación diferenciada (FACP) siendo esta el resultado de la transformación Box-Cox para la estabilización y decrecimiento de la varianza, con un comportamiento mucho mejor, en donde su tasa de decrecimiento es mayor.




FIGURA 10. Función de Autocorrelación vs Retardo.

En la **Tabla 1** se muestran algunos resultados obtenidos, en dónde se compara el valor con el modelo ARIMA y el resultado real, además se visualiza el error porcentual de cada estimación.

No. Datos	Día	Dato Real (\$/kWh)	Dato Predicción (\$/kWh)	Error (%)
1	68	213,0	211,97	0,484
2	70	210,7	209,37	0,63
3	73	210,0	210,55	0,262
4	78	210,6	208,8	0,855
5	80	212,8	210,57	1,048
6	86	220,7	217,01	1,672
7	89	228,4	194,25	14,952
8	93	235,7	234,05	2,722
9	97	246,3	245,31	0,402
10	102	249,0	246,99	0,807
11	107	247,6	245,67	0,779
12	112	253,7	248,74	1,955

13	115	256.0	254,81	0,465
14	117	260,4	255,87	1,740
15	120	260,4	259,92	0,184
16	125	258,9	258,98	0,031
17	127	257,7	256,71	0,384
18	130	257,3	257,43	0,051
19	132	258,9	257,46	0,556
20	135	257,2	257,72	0,202
21	138	257,5	256,78	0,280
22	140	257,6	257,02	0,225
23	142	257,5	257,34	0,062
24	144	261,1	257,02	1,563
25	147	262,8	263,08	0,107

TABLA 1. Resultados ARIMA (Ejemplo Base)

En la Tabla 2, se realiza una comparación entre el comportamiento del modelo ARIMA propuesto usando dos bases de datos, una es la base de datos de la UPME y la otra es la base de datos de los autores de [39], allí se muestra el comportamiento en los resultados de predicción obtenidos, de manera que el promedio del error porcentual en el caso de mercado eléctrico colombiano es menor, esto simplemente significa que el proceso de parametrización del modelo es correcto mas no una mejora en la metodología.

No. Datos	Día	Dato Real (\$/kWh)	Dato Predicción (\$/kWh)	Error (%) Mercado eléctrico colombiano	Error (%) Mercado Diario Peninsular Español
1	68	213,0	211,97	0,484	0,979
2	70	210,7	209,37	0,63	0,406
3	73	210,0	210,55	0,262	6,159
4	78	210,6	208,8	0,855	4,854
5	80	212,8	210,57	1,048	0,434
6	86	220,7	217,01	1,672	4,960
7	89	228,4	194,25	14,952	0,500
8	93	235,7	234,05	2,722	4,134
9	97	246,3	245,31	0,402	0,684
10	102	249.0	246,99	0,807	0,269

11	107	247,6	245,67	0,779	28,244
12	112	253,7	248,74	1,955	0,369
13	115	256,0	254,81	0,465	0,097
14	117	260,4	255,87	1,740	1,235
15	120	260,4	259,92	0,184	1,217
16	125	258,9	258,98	0,031	0,714
17	127	257,7	256,71	0,384	0,377
18	130	257,3	257,43	0,051	0,743
19	132	258,9	257,46	0,556	3,663
20	135	257,2	257,72	0,202	2,249
21	138	257,5	256,78	0,280	0,328
22	140	257,6	257,02	0,225	8,766
23	142	257,5	257,34	0,062	0,855
24	144	261,1	257,02	1,563	0,730
25	147	262,8	263,08	0,107	0,867
			Promedio del error	1,351	3,076

TABLA 2. Comparativo error porcentual

A continuación, se mostrarán los resultados obtenidos al aplicar el modelo auto regresivo de media móvil (ARIMA) a los datos tomados para la predicción del precio spot de la energía eléctrica en el sistema eléctrico colombiano. Se tendrán en cuenta las propiedades de los datos ya mencionadas anteriormente y se graficará su comportamiento dependiendo cada punto, además de esto, se compararán los resultados con el dato real y se estimará un error porcentual para cada dato.

Caso estudio

Para el caso de estudio, se tiene como muestra, una base de datos con los valores del precio spot de energía eléctrica en Colombia dada desde el año 2002 hasta 2016 día a día; los datos tomados de la base de datos por la Unidad de Planeación Minero-Energética (UPME).

A continuación, se mostrarán algunos de los resultados obtenidos a partir de la modelación ARIMA, igualmente para este caso, se tienen en cuenta las características y el comportamiento estocástico de los datos.

El primer dato tomado como referencia es el dato número 300, el cual pertenece al día a predecir; la primera grafica (Figura 10) que se observa es la gráfica de la función de auto correlación de los datos tomados hasta el punto $n-1$ es decir hasta el dato número 299, en la gráfica se puede ver un comportamiento decreciente lento en donde se observa un acercamiento a cero a partir del dato 20 en adelante con una alternancia en los valores a través del eje del tiempo, esto nos lleva a utilizar la herramienta ya mencionada para diferenciar la serie y así obtener una aproximación en su función de auto correlación de una forma más rápida.




FIGURA 11. Función De Auto Correlación vs Retardo Dato 300

De lo anterior, se procede a utilizar la transformación Cox-Box, para llegar a una función de auto correlación de forma descendente de una manera más rápida, como se muestra en la Figura 11, en donde a partir de los primeros datos (2) la FAC decrece y se acerca a cero.




FIGURA 12. FACP vs Retardo Dato 300

Observando las Figuras 11, se evidencia el comportamiento decreciente exponencial de las funciones de auto correlación FAC y FACP (diferenciada) seguidas de un comportamiento sinusoidal con valores y datos próximos a cero, además de observar el valor significativo del primer número; teniendo presente lo anterior, se deduce que al ser necesario tomar una diferenciación de orden 1 ($d=1$), las partes I ($nt=1$) y MA ($nf=1$) del modelo ARIMA son del mismo orden 1.

A continuación, en las gráficas 12 y 13 se observa la serie dada por los datos de entrenamiento o datos de muestra (color rojo) y contiguamente la línea formada por todos los puntos de predicción desde el día 3 hasta el día $t = 299$, \$76,08; el punto verde que se visualiza caracteriza el valor del precio de la energía eléctrica en el día $t+1$ (300), dando así un valor estimado del precio Spot de \$ 65,04.




FIGURA 13. Visualización dato de predicción 300




FIGURA 14. Visualización dato de predicción 300 (Rango Acotado)

El modelo general al que se ajusta la serie de datos Pr es:

$$pr = \emptyset_1(pr_{t-1} - pr_{t-2}) + pr_{t-1} + c - \theta_1\varepsilon_{t-1} + \varepsilon_t \quad (42)$$

Los parámetros \emptyset_1, c, θ_1 son los pesos definidos para el ajuste de los datos a la función regresiva, dichos valores son calculados al minimizar la suma de residuos al cuadrado, de la siguiente forma:

La función para minimizar es:

$$\sum_{t=3}^T (pr - \emptyset_1(pr_{t-1} - pr_{t-2}) + pr_{t-1} - c + \theta_1\varepsilon_{t-1})^2 \quad (43)$$

Sujeto a

$$-1 \leq \emptyset_1 \leq 1$$

$$-1 \leq \theta_1 \leq 1$$

Los valores de los pesos para cada valor de predicción varían según la cantidad de datos, ya que la función toma valores distintos según su aproximación a la función objetivo.

De lo anterior, se obtienen los resultados para los parámetros \emptyset_1, c, θ_1

$$\emptyset_1 = -0,0967$$

$$c = 0,044$$

$$\theta_1 = 0,174$$

El modelo para la serie de residuos es:

$$\varepsilon_t = pr_t + \emptyset_1(pr_{t-1} - pr_{t-2}) - pr_{t-1} - c - \theta_1\varepsilon_{t-1} \quad (44)$$

La predicción obtenida para el precio spot de energía eléctrica en el día T+1 (300) es de \$ 65.04, al comparar este resultado con la base de datos y su dato real (\$ 65,31) se obtiene un error porcentual de 0,41%-0,0967

A continuación, se mostrarán los resultados de algunos valores predichos.

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
360	61,34	61,53	0,309

TABLA 3. Predicción e Hiperparámetros Día 360




FIGURA 15. Función de Autocorrelación vs Retardo día 360




FIGURA 16. FACP vs Retardo día 360




FIGURA 17. Visualización dato de Predicción 360.




FIGURA 18. Visualización dato de Predicción 360 (Rango Acotado)

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
388	74,05	73,57	0,652

TABLA 4. Predicción e Hiperparámetros Día 388




FIGURA 19. Función de Auto Correlación Día 388.




FIGURA 20. FACP vs Retardo Día 388




FIGURA 21. Visualización Dato de Predicción Día 388




FIGURA 22. Visualización Dato De Predicción Día 388

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
410	71,94	62,17	15,715

TABLA 5. Predicción e Hiperparámetros Día 410




FIGURA 23. Función de Auto Correlación vs Retardo Día 410




FIGURA 24. FACP vs Retardo Día 410




FIGURA 25. Visualización Dato de Predicción Día 410




FIGURA 26. Visualización Dato de Predicción Día 410 (Rango Acotado)

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
490	79,36	73,64	7,768

TABLA 6. Predicción e Hiperparámetros Día 490




FIGURA 27. Función de Auto Correlación vs Retardo Día 490.




FIGURA 28. FACP vs Retardo Día 490




FIGURA 29. Visualización Dato de Predicción Día 490




FIGURA 30. Visualización Dato de Predicción Día 490 (Rango Acotado)

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
520	55,35	58,66	5,643

TABLA 7. Predicción e Hiperparámetros Día 520




FIGURA 31. Función de Auto Correlación vs Retardo Día 520




FIGURA 32. FACP vs Retardo Día 520




FIGURA 33. Visualización Dato de Predicción Día 520




FIGURA 34. Visualización Dato de Predicción Día 520

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
580	63,76	61,08	4,388

TABLA 8. Predicción e Hiperparámetros Día 580




FIGURA 35. Visualización Dato de Predicción Día 580




FIGURA 36. Visualización Dato de Predicción Día 580 (Rango Acotado)




FIGURA 37. Función de Auto Correlación vs Retardo Día 580

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
630	65,92	62,3	5,811

TABLA 9. Predicción e Hiperparámetros Día 630




FIGURA 38. Visualización Dato De Predicción Día 630




FIGURA 39. Visualización Dato de Predicción Día 630 (Rango Acotado)




FIGURA 40. Función de Auto Correlación vs Retardo Día 630




FIGURA 41. FACP vs Retardo Día 630

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
650	56,18	55,11	1,942

TABLA 10. Predicción e Hiperparámetros Día 650




FIGURA 42. Visualización Dato de Predicción Día 650




FIGURA 43. Visualización Dato de Predicción Día 650 (Rango Acotado)




FIGURA 44. Función de Auto Correlación vs Retardo Día 650




FIGURA 45. FACP vs Retardo Día 650

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
710	46,74	48,36	3,344

TABLA 11. Predicción e Hiperparámetros Día 710




FIGURA 46. Visualización Dato de Predicción Día 710




FIGURA 47. Visualización Dato de Predicción Día 710 (Rango Acotado)




FIGURA 48. Función de Auto Correlación vs Retardo Día 710




FIGURA 49. FACP vs Retardo Día 710

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
840	68,89	67,06	2,729

TABLA 12. Predicción e Hiperparámetros Día 840




FIGURA 50. Visualización Dato de Predicción Día 840




FIGURA 51. Visualización Dato de Predicción Día 840 (Rango Acotado)




FIGURA 52. Función de Auto Correlación vs Retardo Día 840




FIGURA 53. FACP vs Retardo Día 840

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
955	57,03	54,74	4,183

TABLA 13. Predicción e Hiperparámetros Día 955




FIGURA 54. Visualización Dato de Predicción Día 955




FIGURA 55. Visualización Dato de Predicción Día 955 (Rango Acotado)




FIGURA 56. Función de Auto Correlación vs Retardo Día 955




FIGURA 57. FACP vs Retardo Día 955

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
1033	73,6705	72,65	1,404

TABLA 14. Predicción e Hiperparámetros Día 1033




FIGURA 58. Visualización Dato de Predicción Día 1033




FIGURA 59. Visualización Dato de Predicción Día 1033 (Rango Acotado)




FIGURA 60. Función de Auto Correlación vs Retardo Día 1033




FIGURA 61. FACP vs Retardo Día 1033

En la **Tabla 15** se muestran los resultados obtenidos, en dónde se compara el valor con el modelo ARIMA y el resultado real para el caso estudio., además se visualiza el error porcentual y los parámetros de sintonización en cada estimación.

Dato de Predicción	Precio (Predicción)	Precio Real	Parámetros			Error
			Phi	C	Theta	
[T+1]	[kWh]	[kWh]				[%]
300	65,04	65,31	-0,096	0,044	-0,174	0,413
360	61,34	61,53	-0,313	0,112	-0,490	0,309
388	74,05	73,57	0,038	-0,017	-0,100	0,652
410	71,94	62,17	0,133	-0,060	-0,356	15,715
490	79,36	73,64	0,014	-0,005	-0,027	7,768
520	55,35	58,66	-0,305	-0,060	-0,010	5,643
540	66,83	66,41	0,440	-0,116	-0,666	0,632
580	63,76	61,08	-0,752	0,183	-0,489	4,388
630	65,92	62,3	-1,641	0,268	0,627	5,811
650	56,18	55,11	0,119	-0,021	0,082	1,942
670	60,93	60,2	-0,007	0,002	0,011	1,213

700	62,80	61,22	-0,629	0,138	-0,719	2,587
710	46,74	48,36	0,883	-0,094	0,518	3,344
733	59,85	59,83	1,030	-0,179	0,501	0,033
758	64,17	63,77	0,890	-0,220	0,915	0,627
790	73,25	64,08	-0,708	0,177	0,351	14,310
805	70,97	71,09	-0,535	0,126	-0,266	0,169
816	73,87	72,66	0,018	-0,004	0,046	1,665
840	68,89	67,06	-0,052	0,012	-0,111	2,729
867	88,78	84,39	-2,003	0,610	0,443	5,202
890	54,42	60,04	0,665	-0,092	0,686	9,360
920	50,23	55,07	-0,452	0,046	0,551	8,789
955	57,03	54,74	-0,587	0,072	0,459	4,183
982	74,35	56,95	1,486	-0,2475	-0,3713	30,5531
1015	69,2	73,27	-0,2828	0,053	0,2083	5,5548
1026	75,2	75,21	-0,3083	0,0684	0,3318	0,0133
1033	73,6705	72,65	-0,6173	0,1289	0,3293	1,4047
1055	65,42	62,12	0,0287	-0,0046	-0,0222	5,3123
1058	65,04	62,6	1,1745	-0,1846	0,063	3,8978
1066	90,59	69,06	1,8846	-0,3957	-0,1996	31,1758
1070	63,2228	63,95	-0,3859	0,0635	-0,8041	1,1371
1072	82,88	68,39	1,646	-0,3064	-0,5525	21,1873
1079	68,57	71,2	0,5927	-0,1014	-0,0158	3,6938
1090	68,95	68,92	-0,074	0,0125	-0,0935	0,0435
1101	79,3518	88,78	0,4621	-0,1029	0,1348	10,6197
1125	78,773	85,74	1,0535	-0,2437	-0,9442	8,1257
1137	81,52	75,47	1,1816	-0,2517	0,6166	8,0164
1140	81,506	71,24	-0,7969	0,1563	0,8579	14,4104
1146	82,51	73,29	-1,8428	0,3277	0,1672	12,5802
1152	79,9277	63,3	-1,5761	0,2614	0,6865	26,2681

TABLA 15. Resultados Modelo de Predicción ARIMA

3.3. Modelación de Regresión Gaussiana

El siguiente método a usar es el método de Regresión Gaussiana en donde se usarán los datos con los valores del precio spot de energía eléctrica en Colombia dada desde el año 2002 hasta 2016, los datos son aportados por la Unidad de Planeación Minero-Energética (UPME) y se acotó el rango a 1000 datos por razones de visualización.

El dato tomado como referencia es el dato número 300 (día a predecir), como forma general del método se propone transformar el vector de datos por medio de una serie de funciones base o kernel, los cuales corresponden al parámetro de peso que representa el sesgo de la función, de ésta forma se calculan los pesos más probables para el punto de localización de la distribución posterior, se calculan nuevamente los hiperparámetros y las correspondientes actualizaciones a los gradientes según la distribución de kernel utilizado, posterior a éste tratamiento se realiza un método de validación cruzada (Hold out) con el 70% de los datos de entrenamiento y el 30 para validación y de ésta forma ajustar los hiperparámetros para cada modelo; por último, se introducen nuevamente los hiperparámetros óptimos (parámetros que a continuación se muestran en la tabla de cada una de las figuras y se ajusta la función de correlación.

➤ Dato 300 método de mínimos cuadrados no lineales




FIGURA 62. Estimación día 300 Mínimos Cuadrados No Lineales




FIGURA 63. Estimación Punto Dato 300 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
300	65,94	65,31	0.96

TABLA 16. Predicción e Hiperparámetros Día 300 Mínimos Cuadrados No Lineales

➤ Dato 300 método de Regresión con Kernel Rígido




FIGURA 64. Estimación Punto Día 300 Usando distribución de Kernel Rígido




FIGURA 65. Estimación Punto Dato 300 Usando Distribución De Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
300	66,69	65,31	2,11

TABLA 17. Predicción e Hiperparámetros Día 300 Distribución de Kernel Rígido

➤ Dato 300 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 66. Estimación Dato 300 Distribución de Kernel de Filtro Adaptativo




FIGURA 67. Estimación Dato 300 Distribución De Kernel De Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
300	63,58	65,31	2,4

TABLA 18. Predicción e Hiperparámetros Día 300 Regresión con Kernel De Filtro Adaptativo

- Comparación grafica entre la los métodos usados basados en su función de distribución (kernel)




FIGURA 68. Comparación de Curvas Por Diferentes Métodos De Kernel




FIGURA 69. Comparación de Curvas Por Diferentes Métodos De Kernel

➤ Dato 360 método de mínimos cuadrados no lineales




FIGURA 70. Estimación Punto Dato 360 Mínimos Cuadrados No Lineales




FIGURA 71. Estimación Punto Dato 360 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
360	61,24	61,53	0,47

TABLA 19. Predicción e Hiperparámetros Día 360 Mínimos Cuadrados No Lineales

➤ Dato 360 método de Regresión con Kernel Rígido




FIGURA 72. Estimación Punto Día 360 Regresión con Kernel Rígido




FIGURA 73. Estimación Punto Día 360 Regresión con Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
360	59,07	61,53	3,9

TABLA 20. Predicción e Hiperparámetros Día 300 Regresión con Kernel Rígido

➤ Dato 360 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 74. Estimación Punto Día 360 Regresión con Kernel del Filtro Adaptativo




FIGURA 75. Estimación Punto Día 360 Regresión con Kernel del Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
360	60,68	61.53	1,38

TABLA 21. Predicción e Hiperparámetros Día 360 Regresión con Kernel del Filtro Adaptativo

- Comparación grafica entre los métodos usados basados en su función de distribución (kernel)




FIGURA 76. Comparación de Curvas Por Diferentes Métodos de Kernel

➤ Dato 410 método de mínimos cuadrados no lineales




FIGURA 77. Estimación Punto Día 410 Mínimos Cuadrados No Lineales




FIGURA 78. Estimación Punto Día 410 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
410	71,36	62,17	17,24

TABLA 22. Predicción e Hiperparámetros Día 410 Mínimos Cuadrados No Lineales

➤ Dato 410 método de Regresión con Kernel Rígido




FIGURA 79. Estimación Punto Día 410 Regresión con Kernel Rígido




FIGURA 80. Estimación Punto Día 410 Regresión con Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
410	72,93	62,17	17,30

TABLA 23. Predicción E Hiperparámetros Día 410 Regresión con Kernel Rígido

➤ Dato 410 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 81. Estimación Punto Día 410 Regresión con Kernel del Filtro Adaptativo




FIGURA 82. Estimación Punto Día 410 Regresión con Kernel del Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
410	71,16	62,17	14,40

TABLA 24. Predicción e Hiperparámetros Día 410 Regresión con Kernel del Filtro Adaptativo

- Comparación grafica entre los métodos usados basados en su función de distribución (kernel)




FIGURA 83. Comparación De Curvas Por Diferentes Métodos De Kernel




FIGURA 84. Comparación De Curvas Por Diferentes Métodos De Kernel

➤ Dato 540 método de mínimos cuadrados no lineales




FIGURA 85. Estimación Punto Dato 540 Mínimos Cuadrados No Lineales




FIGURA 86. Estimación Dato 540 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
540	61,22	66,41	7,81

TABLA 25. Predicción e Hiperparámetros Día 540 Mínimos Cuadrados No Lineales

➤ Dato 540 método de Regresión con Kernel Rígido




FIGURA 87. Estimación Día 540 Regresión con Kernel Rígido




FIGURA 88. Estimación Día 540 Regresión con Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
540	72,73	66,41	9,51

TABLA 26. Predicción e Hiperparámetros Día 540 Regresión con Kernel Rígido

➤ Dato 540 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 89. Estimación Día 540 Regresión con Kernel del Filtro Adaptativo




FIGURA 90. Estimación Punto Dato 540 Regresión con Kernel del Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
540	57,35	66,41	13,64

TABLA 27. Predicción e Hiperparámetros Día 540 Regresión con Kernel del Filtro Adaptativo

- Comparación grafica entre los métodos usados basados en su función de distribución (kernel)




FIGURA 91. Comparación De Curvas Por Diferentes Métodos De Kernel




FIGURA 92. Comparación de Curvas Por Diferentes Métodos De Kernel

➤ Dato 630 método de mínimos cuadrados no lineales




FIGURA 93. Estimación Día 630 Mínimos Cuadrados No Lineales




FIGURA 94. Estimación Día 630 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
630	59,08	62,3	1,86

TABLA 28. Predicción E Hiperparámetros Día 630 Mínimos Cuadrados No Lineales

➤ Dato 300 método de Regresión con Kernel Rígido




FIGURA 95. Estimación Día 300 Regresión con Kernel Rígido




FIGURA 96. Estimación Punto Dato 300 Regresión con Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
630	46,79	62,3	24,8

TABLA 29. Predicción E Hiperparámetros Día 630 Regresión con Kernel Rígido

➤ Dato 630 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 97. Estimación Punto Dato 630 Regresión con Kernel del Filtro Adaptativo




FIGURA 98. Estimación Punto Dato 630 Regresión con Kernel del Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
630	47,57	62,3	23,64

TABLA 30. Predicción e Hiperparámetros Día 540 Regresión con Kernel del Filtro Adaptativo

- Comparación grafica entre los métodos usados basados en su función de distribución (kernel)




FIGURA 99. Comparación De Curvas Por Diferentes Métodos De Kernel




FIGURA 100. Comparación De Curvas Por Diferentes Métodos De Kernel

➤ Dato 670 método de mínimos cuadrados no lineales




FIGURA 101. Estimación Punto Dato 670 Mínimos Cuadrados No Lineales




FIGURA 102. Estimación Punto Dato 670 Mínimos Cuadrados No Lineales

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
670	59,08	60,2	1,86

TABLA 31. Predicción E Hiperparámetros Día 630 Mínimos Cuadrados No Lineales

➤ Dato 670 método de Regresión con Kernel Rígido




FIGURA 103. Estimación Punto Dato 670 Regresión con Kernel Rígido




FIGURA 104. Estimación Punto Dato 670 Regresión con Kernel Rígido

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
670	64,75	60,2	7,5

TABLA 32. Predicción e Hiperparámetros Día 670 Regresión con Kernel Rígido

➤ Dato 670 método de Regresión con Kernel del Filtro Adaptativo




FIGURA 105. Estimación Punto Dato 670 Regresión con Kernel del Filtro Adaptativo




FIGURA 106. Estimación Punto Dato 670 Regresión con Kernel del Filtro Adaptativo

Dato de Predicción	Precio (Predicción)	Precio Real	Error
[T+1]	[kWh]	[kWh]	[%]
670	63,36	60,2	5,2

TABLA 33. Predicción e Hiperparámetros Día 670 Regresión con Kernel del Filtro Adaptativo

- Comparación grafica entre los métodos usados basados en su función de distribución (kernel)




FIGURA 107. Comparación de Curvas Por Diferentes Métodos De Kernel




FIGURA 108. Comparación de Curvas Por Diferentes Métodos De Kernel

		70% Train // 30 %Test			80 %Train // 20 %Test	
Modelo	Dato de Predicción	Precio (Predicción)	Precio Real	Error	Precio (Predicción)	Error
	[T+1]	[\$/kWh]	[\$/kWh]	[%]	[\$/kWh]	[%]
KLMS Regularizado	300	65,6	65,3	0,4594	65,39	0,1378
KLMS Regularizado	360	61,24	61,53	0,4713	61,12	0,6663
KLMS Regularizado	540	65,4	66,41	1,5209	61,02	1,3552
KLMS Regularizado	670	59,08	60,2	1,8605	59,16	1,7276
KLMS Regularizado	710	49,2	48,36	1,737	50,72	4,8801
KLMS Regularizado	733	60,1	59,83	0,4513	61,67	3,0754
KLMS Regularizado	805	70,4	71,09	0,9706	70,4	0,9706
KLMS Regularizado	840	68,02	67,06	1,4316	71,53	1,2526
KLMS Regularizado	867	82,6	84,39	2,1211	83,33	1,2561

TABLA 34. Resultados Modelo KLMS Regularizado

		70% Train // 30 %Test			80 %Train // 20 %Test	
Modelo	Dato de Predicción	Precio (Predicción)	Precio Real	Error	Precio (Predicción)	Error
	[T+1]	[\$/kWh]	[\$/kWh]	[%]	[\$/kWh]	[%]
kernel Rígido	300	71,18	65,3	9,0046	71,03	8,7749
kernel Rígido	360	59,07	61,53	3,998	70,9	15,2283
kernel Rígido	540	72,73	66,41	9,5166	61,43	7,4989
kernel Rígido	670	64,75	60,2	7,5581	48,7	19,103
kernel Rígido	710	32,25	48,36	33,3127	51,97	7,4648
kernel Rígido	790	80,3	64,08	25,3121	67,8	5,8052
kernel Rígido	805	46,86	71,09	34,0836	74,07	4,1919
kernel Rígido	816	61,28	72,66	15,662	76,69	5,5464
kernel Rígido	867	49,43	84,39	41,4267	83,59	0,948

TABLA 35. Resultados Modelo de Kernel Rígido

		70% Train // 30 %Test		
Modelo	Dato de Predicción	Precio (Predicción)	Precio Real	Error
	[T+1]	[\$/kWh]	[\$/kWh]	[%]
Kernel filtro Adaptativo	300	63,58	65,3	2,634
Kernel filtro Adaptativo	360	60,68	61,53	1,3814
Kernel filtro Adaptativo	410	71,16	62,17	14,4604
Kernel filtro Adaptativo	540	57,35	66,41	13,6425
Kernel filtro Adaptativo	670	63,36	60,2	5,2492
Kernel filtro Adaptativo	710	49,07	48,36	1,4682
Kernel filtro Adaptativo	733	57,07	59,83	4,6131
Kernel filtro Adaptativo	758	71,233	63,77	11,703
Kernel filtro Adaptativo	805	72,21	71,09	1,5755
Kernel filtro Adaptativo	816	72,86	72,66	0,2753
Kernel filtro Adaptativo	867	91,15	84,39	8,0104

TABLA 36. Resultados Kernel de filtro Adaptativo

CAPITULO 4

4. CONCLUSIONES

El objetivo principal de este estudio es presentar una serie de técnicas basadas en tratamientos estadísticos y matemáticos para la predicción del precio spot de la energía eléctrica en el mercado de energía colombiano, teniendo en cuenta los datos históricos arrojados por la base de datos de la Unidad de Planeamiento Minero Energética (UPME), los cuales se basan en la trazabilidad horaria publicada día a día para el mercado eléctrico colombiano.

Los datos analizados son los precios publicados durante el periodo comprendido entre enero 1 de 2002 hasta diciembre 31 de 2016, y son de naturaleza estocástica, en donde en periodos de tiempo se observan picos y valles que son típicos de la operación del sistema (comportamiento estacional), además se ha incluido una componente de perturbación (ruido blanco gaussiano).

De acuerdo a las técnicas usadas para la predicción del precio spot de energía eléctrica, se observó que el modelo de cada uno de los casos en particular relaciona los datos de acuerdo a la base fundamental y a la estructura matemática de la técnica.

De acuerdo al modelo de series temporales auto regresivo de medias móviles (ARIMA), en donde su mayor ventaja es que sin importar la naturaleza estocástica de los datos, su estructura se basa en media cero, varianza constante finita y auto correlaciones decrecientes, se puede observar que es una buena aproximación del precio spot, sin embargo se visualizan varios inconvenientes, uno de ellos es que entre mayor sea la cantidad de datos, el error cuadrático medio aumenta, debido a que se presenta un fenómeno parecido al sobre entrenamiento, ya que entre mayor sea la cantidad de datos mayor es el coeficiente de correlación, por lo que la aproximación del polinomio regresivo tendría un incremento en la medida que se incluye cada dato, por lo tanto el resultado final de la estimación estaría siendo afectado por dicho incremento.

Teniendo presente los 3 métodos de distribución de kernel usados, se concluye que los métodos de distribución de mínimos cuadrados no lineales y de filtro adaptativo presentan una excelente respuesta

al seguimiento de la curva de comportamiento de los datos, además de una aproximación muy exacta al valor de predicción, como premisa al caso de estudio, el cual no depende de tiempo de cómputo, el método que mejor se comportó fue el método usando kernel por mínimos cuadrados no lineales (KLMS Regularizado).

La sintonización de los parámetros para el método de kernel de filtro adaptativo deberá ejecutarse con una técnica de optimización en lugar de un método heurístico para generar mejores aproximaciones.

La técnica de kernel rígido fue el método que menos se ajustó a la curva de datos, ya que se sesga en gran medida los valores de los pesos asociados al seguimiento y predicción del modelo

Como parte de trabajos futuros, se proponen algunas mejoras teniendo presente que el tratamiento de datos para todos los casos usados y la caracterización de las funciones y de sus hiperparámetros iniciales fueron propuestos de forma determinística, y cuya afinación se deriva del proceso estadístico matemático de cada método, en aras de mejorar los modelos o las metodologías tanto en disminución de iteraciones, tiempo de cómputo, y exactitud en el valor predicho es de resaltar que se deberán usar métodos de optimización para elegir los hiperparámetros iniciales para generar mayor grado de precisión, dependiendo de la aplicación particular y los valores de convergencia deseados.